



# Intercomparaison et développement de modèles statistiques pour la régionalisation du climat

Pradeebane Vaithinada Ayar

## ► To cite this version:

Pradeebane Vaithinada Ayar. Intercomparaison et développement de modèles statistiques pour la régionalisation du climat. Sciences de la Terre. Université Paris Saclay (COMUE), 2016. Français. NNT : 2016SACLV010 . tel-01370008

**HAL Id: tel-01370008**

**<https://theses.hal.science/tel-01370008>**

Submitted on 21 Sep 2016

**HAL** is a multi-disciplinary open access archive for the deposit and dissemination of scientific research documents, whether they are published or not. The documents may come from teaching and research institutions in France or abroad, or from public or private research centers.

L'archive ouverte pluridisciplinaire **HAL**, est destinée au dépôt et à la diffusion de documents scientifiques de niveau recherche, publiés ou non, émanant des établissements d'enseignement et de recherche français ou étrangers, des laboratoires publics ou privés.

NNT : 2016SACLV010

THÈSE DE DOCTORAT  
DE  
L'UNIVERSITÉ PARIS-SACLAY  
PRÉPARÉE À  
L'UNIVERSITÉ VERSAILLES SAINT-QUENTIN EN YVELINES

Ecole Doctorale N°129  
Sciences de l'Environnement d'Ile de France  
Spécialité : Météorologie, océanographie physique de l'Environnement

Par

**M. Pradeebane VAITTINADA AYAR**

Intercomparaison et développement de modèles statistiques pour  
la régionalisation du climat

Thèse présentée et soutenue à Gif-sur-Yvette, le 22 janvier 2016:

Composition du Jury :

<b>Mme. Sylvie THIRIA</b>	Professeur, Université de Versailles Saint-Quentin	Présidente
<b>M. Thierry LEBEL</b>	Directeur de Recherche, LTHE (Grenoble), IRD	Rapporteur
<b>M. Etienne LEBLOIS</b>	Ingénieur en chef des ponts, des eaux et des forêts, IRSTEA (Lyon)	Rapporteur
<b>M. Philippe DROBINSKI</b>	Directeur de Recherche, LMD (Palaiseau), CNRS	Examineur
<b>M. Jean-Philippe VIDAL</b>	Chargé de Recherche, IRSTEA (Lyon)	Examineur
<b>M. Mathieu VRAC</b>	Chargé de Recherche, LSCE (Gif-sur-Yvette), CNRS	Directeur de thèse
<b>M. Henning RUST</b>	Chercheur, Institut für Meteorologie (Berlin)	Invité



**Titre : Intercomparaison et développement de modèles statistiques pour la régionalisation du climat**

**Mots clés :** Climatologie statistique, downscaling statistique, modèle spatial, intercomparaison, correction de biais, régime de temps saisonnier

**Résumé :** L'étude de la variabilité du climat est désormais indispensable pour anticiper les conséquences des changements climatiques futurs. Nous disposons pour cela de quantité de données issues de modèles de circulation générale (GCMs). Néanmoins, ces modèles ne permettent qu'une résolution partielle des interactions entre le climat et les activités humaines entre autres parce que ces modèles ont des résolutions spatiales souvent trop faibles. Il existe aujourd'hui toute une variété de modèles répondant à cette problématique et dont l'objectif est de générer des variables climatiques à l'échelle locale à partir de variables à grande échelle : ce sont les modèles de régionalisation ou encore appelés modèles de réduction d'échelle spatiale ou de downscaling en anglais.

Cette thèse a pour objectif d'approfondir les connaissances à propos des modèles de downscaling statistiques (SDMs) parmi lesquels on retrouve plusieurs approches. Le travail s'articule autour de quatre objectifs : (i) comparer des modèles de réduction d'échelle statistiques (et dynamiques), (ii) étudier l'influence des biais des GCMs sur les SDMs au moyen d'une procédure de correction

de biais, (iii) développer un modèle de réduction d'échelle qui prenne en compte la non-stationnarité spatiale et temporelle du climat dans un contexte de modélisation dite *spatiale* et enfin, (iv) établir une définition des saisons à partir d'une modélisation des régimes de circulation atmosphérique ou régimes de temps.

L'intercomparaison de modèles de downscaling a permis de mettre au point une méthode de sélection de modèles en fonction des besoins de l'utilisateur. L'étude des biais des GCMs révèle une influence indéniable de ces derniers sur les sorties de SDMs et les apports de la correction des biais. Les différentes étapes du développement d'un modèle spatial de réduction d'échelle donnent des résultats très encourageants. La définition des saisons par des régimes de temps se révèle être un outil efficace d'analyse et de modélisation saisonnière.

Tous ces travaux de "Climatologie Statistique" ouvrent des perspectives pertinentes, non seulement en termes méthodologiques ou de compréhension de climat à l'échelle locale, mais aussi d'utilisations par les acteurs de la société.

**Title : Intercomparison and development of statistical models for climate downscaling**

**Keywords :** Statistical Climatology, statistical downscaling, spatial modelling, intercomparison, bias correction, weather regime

**Abstract :** The study of climate variability is vital in order to understand and anticipate the consequences of future climate changes. Large data sets generated by general circulation models (GCMs) are currently available and enable us to conduct studies in that direction. However, these models resolve only partially the interactions between climate and human activities, namely due to their coarse resolution. Nowadays there is a large variety of models coping with this issue and aiming at generating climate variables at local scale from large-scale variables : the downscaling models.

The aim of this thesis is to increase the knowledge about statistical downscaling models (SDMs) wherein there is many approaches. The work conducted here pursues four main goals : (i) to discriminate statistical (and dynamical) downscaling models, (ii) to study the influences of GCMs biases on the SDMs through a bias correction scheme, (iii) to develop a statistical downscaling model

accounting for climate spatial and temporal non-stationarity in a spatial modelling context and finally, (iv) to define seasons thanks to a weather typing modelling.

The intercomparison of downscaling models led to set up a model selection methodology according to the end-users needs. The study of the biases of the GCMs reveals the impacts of those biases on the SDMs simulations and the positive contributions of the bias correction procedure. The different steps of the spatial SDM development bring some interesting and encouraging results. The seasons defined by the weather regimes are relevant for seasonal analyses and modelling.

All those works conducted in a "Statistical Climatology" framework lead to many relevant perspectives, not only in terms of methodology or knowledge about local-scale climate, but also in terms of use by the society.





---

# Remerciements

Au moment d'achever ce manuscrit, c'est avec une certaine émotion et nostalgie que je rédige ces quelques lignes.

Je tiens tout d'abord à remercier sincèrement mon directeur de thèse Mathieu VRAC, qui m'a guidé avec d'excellentes idées et un goût pour la recherche particulièrement communicatif. Sa disponibilité et sa rigueur scientifique m'ont énormément apporté tout au long de ce travail. Il a su, par sa présence subtile, m'amener de l'état d'étudiant à appréhender le métier de chercheur. Je remercie également le LSCE de m'avoir accueilli en son sein.

Je suis très reconnaissant aux membres du jury pour avoir pris le temps de donner rigoureusement leur point de vue sur mon travail de thèse. Merci donc à Thierry Lebel, Etienne Leblois, Sylvie Thiria, Philippe Drobinski, Jean-Philippe Vidal et Henning Rust.

Je remercie également mes co-auteurs qui ont, par leurs apports, considérablement amélioré les publications issus de mes travaux. Je pense à Pascal Yiou, Sophie Bastin, Julie Carreau, Michel Déqué et Clemente Gallardo.

Cette thèse n'aurait pu voir le jour sans le soutien et la générosité de tous ceux qui font ce que nous sommes. En premier lieu, je souhaite remercier ma mère qui, grâce à sa bienveillance, sa rigueur, aux valeurs humaines inculquées, à son soutien indéfectible et son goût des sciences, m'a permis d'en arriver jusque-là. Je remercie mon frère jumeau, ma moitié, avec qui je partage absolument tout. Je remercie mon professeur de Physique de terminale, M. Belazreg, qui a su me prendre en main au bon moment et m'encourager dans cette voie. Enfin, je remercie Ninon pour son aide, sa patience et sa compréhension.

Comment oublier de remercier ceux qui font le quotidien du labo et ont, par leur gentillesse, su me supporter : Benjamin, Robin, Marc, Thomas N, Thomas V, Gérémy, Cédric, Sébastien, Madeleine-Sophie, Sarah, Sabine, Davide, Yohan, Ara, mes deux relecteurs de chocs Isabelle et John et enfin Jean-Yves pour son aide et ses friandises et tous ceux que j'ai oublié.



---

# Table des matières

RÉSUMÉ.....	II
REMERCIEMENTS.....	V
PRÉFACE.....	1
I. INTRODUCTION - CONTEXTE - OBJECTIFS.....	3
1. Introduction.....	4
2. La climatologie statistique : de l'analyse de données à la modélisation.....	5
3. La régionalisation du climat ou comment traduire la circulation atmosphérique à l'échelle de stations.....	8
4. Cadre et objectifs de la thèse.....	15
5. Plan du manuscrit .....	18
II. INTERCOMPARAISON DE DIFFÉRENTES APPROCHES DE RÉGIONALISATION DU CLIMAT DANS UN CONTEXTE DE CLIMAT PRÉSENT.....	25
1. Introduction.....	26
2. Publication : Intercomparison of statistical and dynamical downscaling models under the EURO- and MED-CORDEX initiative framework : present climate evaluations.....	27
3. Étude complémentaire concernant le choix du seuil .....	59
4. Perspectives.....	63
5. Synthèse des résultats .....	65
III. TESTS DE SENSIBILITÉ DES MODÈLES DE RÉGIONALISATION STATISTIQUE AUX BIAIS DES GCMS EN CLIMAT CTRL ET FUTUR.....	73
1. Introduction.....	74
2. Publication : Influence of bias correcting predictors on statistical downscaling models.....	77
3. Perspectives.....	99
4. Synthèse des résultats .....	100
IV. DÉVELOPPEMENT D'UN MODÈLE SPATIAL DE DOWNSCALING : SPAWGEN.....	105
1. Introduction.....	106
2. Le cadre statistique : les processus spatiaux .....	109
3. Le modèle : SpaWGEN.....	111
4. Données.....	115

5. Évaluation du modèle .....	117
6. Conclusions et perspectives.....	135
7. Synthèse des résultats .....	144
V. RÉGIMES DE TEMPS : VERS UNE NOUVELLE DÉFINITION DES SAISONS ?.....	149
1. Introduction.....	150
2. Publication : Trends and variability of seasonal weather regimes .....	151
3. Un outil d'analyse opérationnel? .....	164
4. Perspectives.....	166
5. Synthèse des résultats .....	167
VI. CONCLUSIONS & PERSPECTIVES.....	171
1. Retour sur les motivations.....	172
2. Conclusions principales.....	173
3. Perspectives.....	177
 <b>Annexes</b>	 <b>183</b>
A. MATÉRIEL SUPPLÉMENTAIRE CHAPITRE II.....	185
B. CONTINUITÉ ET DÉRIVABILITÉ D'UN PROCESSUS SPATIAL.....	195
C. MATÉRIEL SUPPLÉMENTAIRE CHAPITRE IV.....	197

---

# Préface

C'est à l'issue des mes études d'ingénieur et une spécialisation en mathématiques appliquées que j'ai été initié un peu par hasard, aux sciences du climat. J'ai notamment découvert les échanges possibles entre les statistiques et la climatologie. Ma première expérience dans le domaine s'est concrétisée par un stage de fin d'étude auprès de Mathieu Vrac. Je suis ensuite parti une année vers d'autres domaines pour mieux y revenir d'abord en tant qu'ingénieur puis, aux côtés de Mathieu tant que doctorant.

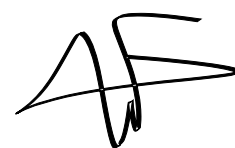
C'est au sein du projet ANR StaRMIP que j'ai eu la chance de pouvoir évoluer durant ces trois années dans un cadre interdisciplinaire pour mener mes travaux. Ce projet a pour but de comparer des modèles de régionalisation statistiques et de réaliser des études d'impacts hydrologiques. Ma tâche a essentiellement consisté à réaliser des simulations régionales à des fins d'intercomparaison et à développer un nouveau modèle.

Ce manuscrit reflète le travail effectué durant trois ans et expose les principaux questionnements, résultats, conclusions et perspectives que j'ai pu y établir. Pour une première lecture ou une lecture en accéléré de ce manuscrit, le lecteur pourra, après le chapitre introductif, parcourir les différents encadrés de fin de chapitre qui synthétisent leur contenu. Ces synthèses constituent en quelque sorte un résumé étendu de ce travail de thèse.

Chaque chapitre aborde un axe de recherche quasiment autonome, et forme une entité structurale avec introduction et conclusions spécifiques. Quatre chapitres ainsi constitués sont encadrés d'une introduction générale (CHAPITRE I) et de conclusions et perspectives générales (CHAPITRE VI).

J'espère que le lecteur trouvera un aperçu clair et agréable de mes travaux...

Gif-sur-Yvette  
Le 1<sup>er</sup> décembre 2015  
Pradeebane Vaithinada Ayar









# Introduction - Contexte - Objectifs

Où l'on décrit la place des statistiques en climatologie et les apports de ce manuscrit à la climatologie statistique.

1. Introduction.....	4
2. La climatologie statistique : de l'analyse de données à la modélisation.....	5
2.1. Les données climatiques . . . . .	5
2.2. Contexte d'étude : la variabilité climatique . . . . .	7
3. La régionalisation du climat ou comment traduire la circulation atmosphérique à l'échelle de stations.....	8
3.1. Le nécessité d'une modélisation régionale . . . . .	8
3.2. Un vaste choix de modèle . . . . .	10
3.3. Hypothèses implicites et limitations des modèles de régionalisation statistique . . . . .	14
4. Cadre et objectifs de la thèse.....	15
4.1. Questionnement scientifique . . . . .	15
4.2. Objectifs de la thèse . . . . .	17
5. Plan du mansucrit .....	18

# 1. Introduction

L'homme est très largement soumis et influencé par l'environnement qui l'entoure. Même si nous avons parfois tendance à l'oublier, ses activités au quotidien dépendent grandement de son habitat et de ce qui le compose. Le climat en est une composante majeure et les populations sont de plus en plus exposées aux phénomènes climatiques [WG2AR5IPCC, 2014].

L'étude du climat ou climatologie est aujourd'hui une question sociétale majeure. En effet, que ce soit pour se nourrir, se déplacer, travailler ou se loger, nous sommes impactés par des événements tels que les crues, les sécheresses, les vagues de chaleur, les vents violents... Bien que toutes ces catastrophes ont toujours existé et continueront d'exister, il se pourrait que leurs conséquences soient amplifiées d'une part par la vulnérabilité des populations qui se définit en fonction de la démographie, des infrastructures et de la préparation des populations faces aux dangers et d'autre part par une augmentation de la variabilité climatique qui serait causée par le changement climatique qui se manifeste entre autres par un réchauffement global dont l'origine anthropique ne fait plus aucun doute au sein de la communauté scientifique.

Ainsi, il est désormais nécessaire voire vital d'augmenter l'état des connaissances sur le climat en général et sur les conditions climatiques spécifiques mettant en jeu la sécurité des populations. En effet, une situation à risques n'apparaît pas nécessairement à cause d'un seul phénomène mais parfois à cause d'une combinaison de plusieurs d'entre eux. Pour comprendre les processus mis en jeu et leurs interactions, il est nécessaire de cerner chacun des phénomènes afin de mettre en place des mesures de protections et de préventions adaptées. La mitigation des conséquences de ces événements nécessite d'étudier leurs propriétés. L'étude statistique du climat ou climatologie statistique se révèle pertinente dans l'étude de ces propriétés.

La climatologie statistique a très longtemps été et est toujours considérée comme un outil d'analyse des sorties des modèles dynamiques qu'ils soient globaux (modèles globaux de circulation atmosphérique, GCM) ou régionaux (modèles de climat régionaux, RCMs). Cela permet d'en étudier les propriétés statistiques comme les tendances ou encore les extrêmes. Cela nécessite l'estimation de paramètres par exemple, en ajustant à partir de données un modèle linéaire ou un modèle théorique d'une distribution extrême afin de caractériser ce type de propriétés. Dans ce manuscrit, les statistiques prendront une dimension supplémentaire : certes dans la plupart des cas, cela consistera à estimer des paramètres à partir des données, mais dans les travaux menés dans la suite ces paramètres serviront à effectuer des simulations et plus uniquement à des fins d'analyse. Nous considérerons donc les statistiques comme des modèles à part entière.

Les travaux présentés dans ce manuscrit se situent dans ce contexte. L'ensemble des travaux sera centré autour de l'Europe de l'Ouest. Nous nous intéresserons aussi bien à la circulation atmosphérique à grande échelle qu'aux précipitations et aux températures à l'échelle locale. Nous chercherons à modéliser et à caractériser le changement ou la variabilité du climat et ceci d'un point de vue non seulement régional mais aussi local.

Notre démarche sera identique pour l'ensemble de nos approches : nous commencerons par étudier le comportement des modèles dans un contexte climatique d'un passé récent que nous appellerons climat

présent, historique ou contrôle (CTRL) en fonction de la nature des données utilisées (réanalyses ou GCM) et le cas échéant nous travaillerons dans la cadre de projections climatiques futures au XXI<sup>e</sup> siècle.

La suite de ce chapitre nous permettra d'introduire les notions majeures de la climatologie statistique et de situer le contexte des travaux menés dans ce manuscrit. Cette section ne se veut pas exhaustive, il existe des recueils donnant une vue d'ensemble de la climatologie statistique [e.g., STORCH & ZWIERS, 2001 ; WILKS, 2011 ]. Nous nous attachons à introduire les aspects de la climatologie statistique qui serviront à notre propos dans la suite de ce manuscrit.

## 2. La climatologie statistique : de l'analyse de données à la modélisation

Aujourd'hui, nous disposons d'un large panel de données nécessaires à l'étude du climat ou *climatologie*. C'est ici que se fait la rencontre entre la climatologie et les statistiques : c'est le domaine de la "*climatologie statistique*". Les travaux développés dans ce manuscrit s'inscrivent au carrefour de ces deux disciplines. Progressivement, climatologie statistique a fait l'objet de plus en plus d'intérêt de la part des climatologues et la modélisation statistique appliquée au climat se révèle être un réel atout pour l'étude et la compréhension de la variabilité du climat et de l'environnement. La communauté climatologie statistique est maintenant bien développée. Dans la suite de cette section, nous évoquerons quelques axes de recherche menés au sein de cette communauté. Nous ne présenterons pas ici l'ensemble de la recherche menée dans ce domaine, seuls quelques exemples seront abordés afin d'illustrer le propos d'une part et de situer les travaux menés dans ce manuscrit dans le domaine d'autre part.

Il y a en effet plusieurs approches pour caractériser ou modéliser les propriétés statistiques des données climatiques. On peut par exemple s'intéresser aux événements extrêmes. Il existe tout un axe de recherche se basant sur la théorie des valeurs extrêmes [COLES, 2001]. Cette théorie permet à la fois de caractériser ou de modéliser les événements extrêmes. Par exemple, COOLEY & SAIN [2010] et PANTHOU et al. [2012] s'attachent à modéliser les extrêmes de précipitations de façon spatialement cohérente sur une région donnée. Un autre domaine s'attache à caractériser les signaux de changements climatiques d'un point de vue statistique et à évaluer les contributions physiques relatives provoquant ces changements en attribuant un degré de confiance [e.g., RIBES et al., 2010 ], c'est le domaine de la détection-attribution [*cf.* "Intergovernmental Panel on Climate Change", IPCC, BINDOFF et al., 2013 ].

Un besoin évident et incontournable de la climatologie statistique et des statistiques en général est l'obligation d'avoir des données. Nous commencerons par introduire quelques types de données que nous allons utiliser ici.

### 2.1. Les données climatiques

La climatologie statistique est complètement dépendante des données disponibles. Nous disposons actuellement de plusieurs types de données que nous utiliserons en fonction des besoins et de l'étude :

les observations, les produits de réanalyse, les sorties de modèles de circulation générale globale (general circulation models, GCM) ou de climat régional (regional climate models, RCMs).

### 2.1.1. Données d'observations

Ces données peuvent provenir de stations climatiques, de satellites ou encore de radars. Dans notre cas, elles peuvent servir de référence pour l'évaluation de modèles ou servir à la calibration de modèles statistiques comme nous le verrons dans la suite. Les travaux développés dans ce manuscrit seront essentiellement basés sur des données issues du projet "European Climate Assessment & Dataset" (ECA&D). Nous utiliserons le produit grillé à la résolution spatiale de  $0.44^\circ$  [HAYLOCK et al., 2008] et les données de stations [KLEIN TANK et al., 2002] selon les cas, ainsi que les séries quotidiennes de références de Météo France [DÉQUÉ, 2007]. Dans tous les cas, nous parlerons alors d'échelle locale.

### 2.1.2. Les réanalyses

La réanalyse est une méthode combinant un modèle de prévision météorologique basé sur des équations physiques et des observations pour générer des données climatiques reflétant la réalité ou plutôt une "bonne" approximation de la réalité, et cela en général à l'échelle globale et pour plusieurs décennies. Cela permet de produire tout un ensemble de variables qui sont dites soit "pronostiques" c'est à dire calculées directement par le modèle ou "diagnostiques" c'est à dire calculées après coup à partir des précédentes. Cet ensemble de variables est appelé *réanalyse*.

Les réanalyses les plus connues sont celles du *National Center for Environmental Prediction* [par exemple les réanalyses NCEP, KALNAY et al., 1996 ] ou le *European Center for Medium-Range Weather Forecasts* [ECMWF, les réanalyses ERA-Interim DEE et al., 2011 ]. Nous remarquons malgré tout des différences importantes selon les bases de données de réanalyses, surtout dans les régions où les observations sont rares. De plus, la diversité des réanalyses est issue du modèle de prévision, du schéma d'assimilation, de la résolution et de la sélection d'observations.

Cette réalité illustre autant les défis que les incertitudes inhérentes à la représentation du climat présent. En dépit de ces incertitudes, les réanalyses représentent un outil indispensable pour l'étude du climat car elles permettent d'analyser de nombreuses variables et leurs interactions. Elles sont également utilisées pour valider les modèles climatiques (GCMs ou RCMs) ou pour forcer les RCMs en climat présent.

### 2.1.3. Les modèles de climat

Un modèle de climat permet de simuler diverses variables climatiques (comme la vitesse du vent, l'humidité ou la pression atmosphérique...) ainsi que les différentes interactions physiques du système terrestre. Ces modèles reposent avant tout sur les équations fondamentales de la mécanique des fluides suivant les principes de conservation de la masse, de l'énergie et de l'eau décrivant le comportement de l'atmosphère et de l'océan. Ces équations décrivent l'évolution de la répartition de la masse, de l'énergie et de l'humidité dans l'espace tridimensionnel par le vent et les courants océaniques, par les échanges et interactions entre les composantes du système climatique, tout en tenant compte des sources (gains) et des puits (pertes). Ces équations sont fortement non-linéaires et de nature chaotique. Dans le but de minimiser les simplifications, il convient de résoudre le système d'équations grâce à

des méthodes numériques (ou schémas numériques) qui permettent de transposer les équations sur des grilles à trois dimensions spatiales.

Pour résumer, un modèle physique de climat est donc un simulateur constitué du code informatique qui permet la représentation discrète (i.e. sur des maillages) dans l'espace et le temps (4e dimension) des équations fondamentales de la mécanique et de la thermodynamique résolues avec un schéma numérique. Il nécessite entre autres des données décrivant la surface planétaire (types de sols, types de végétation, contours continentaux, localisation et bathymétrie des grands plans d'eau, localisation et hauteur des montagnes, etc.), la composition chimique de son atmosphère (incluant les gaz à effet de serre, l'ozone et les aérosols), ainsi que d'autres caractéristiques physiques essentielles (e.g. la constante gravitationnelle, la constante solaire, l'angle zénithal du soleil).

À partir de cela, est produit ce qu'on appelle une simulation numérique qui consiste à exécuter un modèle de climat pour une période donnée (de quelques années jusqu'à plusieurs millénaires). Ainsi, une simulation climatique contient plus d'une centaine de variables descriptives du climat (température, vent, pression, précipitation, neige, etc.), toutes cohérentes entre elles d'un point à l'autre de la grille pour de très longues périodes. Elles proviennent des équations fondamentales, ainsi que de ce qu'on appelle des paramétrisations physiques qui permettent de considérer les processus plus fins que la maille de la grille de calcul.

Les modèles physiques de climat se divisent en deux groupes selon l'étendue de leur grille de calcul : les GCMs et les RCMs. Les premiers offrent une couverture globale généralement à faible résolution spatiale et les suivants une couverture régionale à plus haute résolution spatiale.

Nous parlerons désormais de *données à grande échelle* lorsque nous désignerons les réanalyses ou les GCMs suivant l'usage anglo-saxon qui s'est imposé à notre discipline.

## 2.2. Contexte d'étude : la variabilité climatique

Les variations climatiques se produisent à différentes échelles temporelles et spatiales. Celles-ci ont longtemps été étudiées sous le prisme des modèles globaux de circulation atmosphérique (GCMs) ou des réanalyses ayant une résolution relativement basse (de 100 à 200 km) nécessitant l'utilisation de paramétrisations pour les processus sous-maillages. La circulation atmosphérique est importante puisqu'elle détermine les conditions environnementales auxquelles sont soumis les processus méso- et micro-échelles. Nous disposons aujourd'hui des réanalyses qui remontent à la fin du XIX<sup>e</sup> siècle et couvrent une période de plus 100 ans [e.g., DEE et al., 2014] et de simulations issues des GCMs couvrant la fin du XXI<sup>e</sup> siècle. Nous pouvons entre autres caractériser la variabilité des structures de circulation atmosphérique grâce aux régimes de temps (RTs).

Les régimes de temps sont, depuis quelques décennies, une approche largement utilisée pour caractériser les principaux modes de variabilité de la circulation atmosphérique sur une région donnée [e.g. VRAC & YIOU, 2010]. Ils sont aussi appelés *régimes de temps* ou *régimes de circulation atmosphérique*. On peut définir un régime de temps comme caractérisant une structure atmosphérique récurrente au-dessus d'une région d'intérêt. Ces structures récurrentes sont usuellement décrites à partir de variables de circulation (pression, température, hauteurs de géopotential etc.). Nous supposons généralement que ces structures associées à ces régimes de temps engendrent des conditions

spécifiques à l'échelle locale qui leur sont propres (nous y reviendrons à la SECTION 3.2.2 de ce chapitre).

En climatologie statistique, nous utilisons des méthodes dont le but est de regrouper des individus ayant les mêmes caractéristiques : le clustering. Dans un contexte de clustering climatique, cela consiste à regrouper les champs atmosphériques qui se “ressemblent” en se basant sur la notion de distance. La méthode la plus populaire est sans doute la méthode par nuées dynamiques introduite par DIDAY [1974]. Cette méthode a ensuite été énormément utilisée, notamment pour l'étude des états récurrents [MICHELANGELI et al., 1995] ou les extrêmes [YIOU & NOGAJ, 2004] en Atlantique Nord ou encore pour l'étude de structure de téléconnexions [CASSOU, 2008].

Une large variété de méthodes notamment basées sur les fonctions empiriques orthogonales [Empirical orthogonal functions, EOFs BARNSTON & LIVEZEY, 1987 ; VAUTARD, 1990 ] ou sur des indices de pression [CONWAY et al., 1996 ; GOODESS & JONES, 2002] a vu le jour. Nous trouvons également les méthodes hiérarchiques ascendantes [HAC, WARD, 1963 ]. Des méthodes basées sur des réseaux de neurones artificiels peuvent être utilisées pour définir des RTs : ce sont les “carte auto organisatrices” (Self-Organizing Maps, SOM) créées par KOHONEN [1981] et utilisées dans les études de HEWITSON & CRANE [2006] et NING et al. [2012]. VRAC & YIOU [2010] appliquent entre autres une méthode basée sur la corrélation canonique. Issues de l'intelligence artificielle, des méthodes telles que les *règles floues* (fuzzy rules)(Bardossy et al., 2002) ont été appliquées pour définir des régimes. Dans un contexte de modélisation statistique, une méthode basée sur une définition probabiliste des RTs nous intéresse particulièrement dans ce manuscrit : c'est un modèle de mélange de distributions par “espérance-maximisation” [EM, DEMPSTER et al., 1977 nous y reviendrons au CHAPITRE V].

Bien que très intéressant pour l'étude du climat, les régimes de temps ne permettent qu'une résolution partielle des interactions entre le climat et l'activité humaine. La question est de savoir si, comme on le suppose classiquement lors de l'étude des RTs, les conditions à l'échelle locale découlant de la circulation grande échelle sont stationnaires. Ceci sera l'un des questionnements majeurs de ce manuscrit, à savoir comment répercuter le mieux possible la variabilité à grande échelle sur la climatologie à l'échelle locale.

### 3. La régionalisation du climat ou comment traduire la circulation atmosphérique à l'échelle de stations

Nous entrons ici dans le cœur des travaux de cette thèse : la régionalisation du climat. Nous allons étudier différentes stratégies de modélisation liant l'information à grande échelle à celle à l'échelle de stations météorologiques.

#### 3.1. Le nécessité d'une modélisation régionale

Dans un contexte de changement climatique global, aucun doute ne subsiste sur l'influence de ces changements sur les activités humaines [WG2AR5IPCC, 2014]. Nous constatons en effet une hausse des températures, des niveaux marins, une augmentation des difficultés d'accès à l'eau potable, une extinction massive d'espèces animales ... impactant en retour la vie sur terre. L'étude des impacts

du changement climatique sur l'agriculture, les ressources en eau, la pollution et tout autre facteur environnemental nécessite des simulations d'une autre nature que les GCMs. En effet, le "Groupe d'experts Intergouvernemental sur l'Evolution du Climat" (GIEC ou IPCC en anglais) a mis en place un exercice d'intercomparaison des simulations climatiques issues des principaux modèles de climat global (GCM) contraints par différents scénarios futurs d'émissions de gaz à effet de serre [WG1AR5IPCC, 2013]. Le problème majeur de ces simulations est leur résolution trop faible pour être directement utilisée en entrée de modèles d'impacts (e.g. hydrologiques, écologiques, etc.) qui nécessitent des informations climatiques à plus fine échelle. Ainsi, il est nécessaire de porter les informations des GCMs à une échelle régionale c'est-à-dire à une résolution beaucoup plus fine. Autrement dit, il faut *régionaliser* les simulations climatiques des GCMs, en générant des simulations à haute résolution à partir d'informations à grande échelle. Par régionaliser, nous entendons ici : la réduction de la résolution spatiale sur une région ou certains lieux donnés tels que des stations, bassins versants, etc.

C'est à cette problématique que les modèles de régionalisation du climat apportent une réponse. Dans la majeure partie des travaux, nous aurons ce fil conducteur qui consiste à modéliser des variables à très fine échelle à partir d'information à basse résolution en utilisant des modèles dits de réduction d'échelle ou *downscaling* en anglais. Ceci est schématisé à la FIGURE I.1. Dans la suite, sauf indications contraires, nous utiliserons aussi bien régionalisation, réduction d'échelle ou downscaling de façon équivalente.

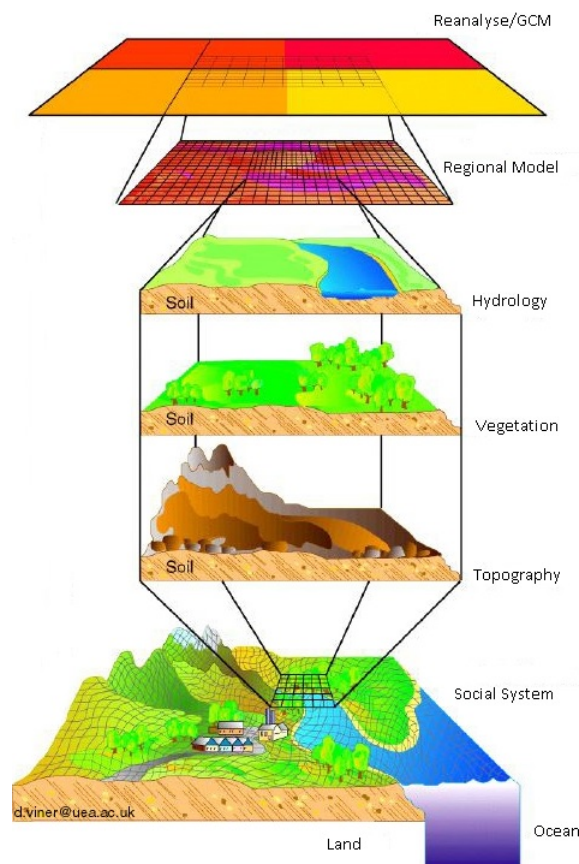


FIGURE I.1 – Schéma représentant le but du downscaling et son utilisation : générer des simulations à haute résolution à partir d'informations à grande échelle qui serviront de donnée d'entrée aux modèles d'impacts (Source : David Viner, Climatic Research Unit, University of East Anglia, UK).



Les modèles de downscaling ont un apport important en terme d'étude climatique. La réduction d'échelle permet d'étudier les processus atmosphériques sous-maille et d'améliorer notre connaissance du système climatique. Cela est possible sur différents temps géologiques en forçant les modèles de downscaling par des données de circulation issues des simulations de climats passés [ou paléo-climat, e.g. au dernier maximum glaciaire VRAC et al., 2007c; LEVAVASSEUR et al., 2011 ], présents ou contrôles [CTRL, BÜRGER et al., 2012b ] ou futurs [e.g. VIGAUD et al., 2013; GAITAN et al., 2014 ]. La contribution de ce manuscrit au domaine se fera essentiellement dans un contexte de climat présent/CTRL et futur, mais l'interprétation physique des modèles reste somme toute limitée et restera en dehors du champ d'étude de cette thèse.

## 3.2. Un vaste choix de modèle

Il existe plusieurs manières de régionaliser les informations climatiques. Globalement, il existe deux grands ensembles d'approches : les modèles dynamiques et les modèles statistiques. Historiquement, les modèles dynamiques sont les premiers à avoir vu le jour : ce sont les modèles de climat régionaux ou RCMs que nous avons rapidement évoqués précédemment. De façon schématique, il existe deux familles de RCMs : soit on considère le RCM comme un GCM ayant une résolution plus fine sur la région d'intérêt [par exemple, DÉQUÉ & PIEDELIEVRE, 1995; HOURDIN et al., 2006 ] soit comme un modèle à aire limitée (limited area model, LAM), c'est à dire un modèle restreint à une région donnée avec une résolution fine et contraint par un GCM au bord du domaine [par exemple, SKAMAROCK et al., 2008 ]. Ces modèles atteignent des résolutions spatiales de 50 à 5km [pour des revues dans le domaine voir LAPRISE et al., 2008; RUMMUKAINEN, 2010 ]. Dans les deux cas, ces modèles cherchent à résoudre les principales équations de la physique de la dynamique régionale de l'atmosphère et des processus mis en jeu à l'échelle sous-maille des GCMs en restant cohérent des points de vue météorologique et hydrologique. Cependant, en dépit de la croissance perpétuelle des capacités informatiques, les moyens et les coûts de calculs nécessaires à la résolution de ces équations sont eux aussi en constante augmentation du fait d'un plus grand nombre de paramètres pris en compte grâce notamment à une résolution plus fine. Ceci limite en partie le nombre, la finesse de la résolution et la période de temps des simulations.

Néanmoins, plusieurs initiatives internationales coordonnant des études entre différents groupes de modélisateurs de climat régional ont été menées dans le monde entier afin de comparer les différents modèles régionaux. Par exemple, sur l'Europe, nous avons :

- le projet MERCURE [1997–2000, MACHENHAUER et al., 1998 ], visant à comparer les RCMs sur l'Europe,
- suivi par le projet PRUDENCE [2001–2004, CHRISTENSEN & CHRISTENSEN, 2007 ], évaluant les projections régionales de scénarios de changements climatiques en Europe,
- prolongé par le projet ENSEMBLES [2004–2009, HEWITT, 2004 ], donnant une estimation de l'incertitude du climat futur par méthode ensembliste pour les GCMs et les RCMs,
- et actuellement en cours, l'initiative CORDEX [Coordinated Regional Climate Downscaling Experiment, GIORGI et al., 2009 ] portant sur la régionalisation de variables climatiques sur une douzaine de régions dans le monde.

Notons qu'il existe d'autres projets d'intercomparaisons de RCMs sur d'autres régions comme le projet RMIP sur l'Asie [FU et al., 2005] ou sur l'Amérique du Nord le projet PIRCS [TAKLE et al., 1999] et NARCCAP [MEARNS et al., 2013]. Or, ces exercices d'intercomparaison sont essentiellement réalisés entre RCMs et omettent ou négligent souvent tout un pan de la modélisation régionale que constituent les modèles statistiques. C'est à cette catégorie de modèles que les travaux menés dans cette thèse vont essentiellement contribuer.

Cette catégorie de modèles ne cherche pas à résoudre les équations de la physique régionale. Les modèles de downscaling ou de réduction d'échelle statistique (en anglais *statistical downscaling models*, SDMs) reposent sur des modélisations statistiques des liens et corrélations entre les variables à grande échelle (issues par exemple des réanalyses et des GCMs qu'on appellera aussi prédicteurs ou covariables) et les variables à l'échelle locale autrement dit les variables d'intérêts (qu'on appellera aussi prédictands).

Les formulations statistiques permettent en général d'effectuer des simulations rapides et peu coûteuses en terme de moyens de calculs. Selon la formulation statistique utilisée, l'approche statistique peut être complémentaire aux RCMs, par exemple la rapidité des simulations permet d'estimer et de modéliser les incertitudes liées aux projections régionales, d'étudier leur propagation au cours du downscaling et de mener des études d'incertitudes d'ensembles [SEMENOV & BARROW, 1997; SEMENOV et al., 1998; SACHINDRA et al., 2014].

La formulation mathématique des SDMs liant les prédictands et les prédicteurs est supposée constante dans le temps. Cela signifie que les relations établies en climat présent restent valables en climat futur. Cela n'implique cependant pas que les propriétés statistiques des prédictands sont constantes dans le temps. En effet, si les propriétés statistiques des prédicteurs à grande échelle changent dans le temps, celles des prédictands changeront en conséquence. Ainsi, si on peut qualifier la relation mathématique de "statique" (ou "stationnaire"), la distribution statistique des prédictands est dite "non-stationnaire".

Dans l'état de l'art, les SDMs peuvent-être classés suivant les quatre groupes ou familles de modèles suivants basés sur : les fonctions de transfert (TFs), les générateurs de temps (weather generators, WGs), les régimes ou types de temps (weather typing, WT) et la correction de biais (model output statistics, MOS).

### 3.2.1. Fonctions de transfert (TFs)

Les SDMs par fonction de transfert regroupent l'ensemble des modèles de régression déterministes "traduisant" les informations à grande échelle à l'échelle locale au travers de régressions linéaires ou non-linéaires selon la nature des liens. On estime la variable à échelle locale  $y$  étant donnée la situation à grande échelle  $x$  par une fonction  $\hat{y} = f(x)$ , où  $f$  est une fonction déterministe de type régression.  $\hat{y}$  est usuellement une estimation de l'espérance conditionnelle  $\mathbb{E}[Y|X = x]$ . Il existe plusieurs autres méthodes de régression dont l'objectif est notamment de donner une estimation d'un quantile en particulier [FRIEDERICH & HENSE, 2007; CANNON, 2011].

Les méthodes de régressions permettent d'extrapoler des valeurs au-delà des bornes d'observation de la période de calibration. Il est important de vérifier que les relations statistiques établies restent valides au moment de l'extrapolation. Le problème majeur de toutes les méthodes de régression

est qu'elles ont tendance à sous-estimer la variance des précipitations, ainsi que la fréquence des événements extrêmes parce qu'en général ces régressions sont supposées donner la meilleure estimation de la moyenne des précipitations observées [ZORITA & STORCH, 1999]. Une solution consiste à utiliser une procédure artificielle d'inflation de la variance [e.g., WILBY et al., 2002], ou encore utiliser une modélisation stochastique au travers de régressions dans un cadre vectorisé de modèles linéaires généralisés [VGML, CHANDLER, 2005] consistant à modéliser les paramètres d'une distribution adaptée à la variable d'intérêt (*cf.* SECTION 3.2.3) au lieu d'un quantile ou de la moyenne.

### 3.2.2. Types de temps (WTs)

Comme évoqué à la SECTION 2.2, les méthodes de clustering climatique visent à classifier les situations de circulation atmosphérique récurrentes à grande échelle en régimes ou types de temps. En contexte de downscaling, ces méthodes supposent que chaque type de temps donné est toujours associé aux mêmes conditions météorologiques locales [e.g., BOÉ et al., 2006; VRAC et al., 2007d; PAGÉ et al., 2010]. Le typage de temps est habituellement utilisé comme une étape de pré-traitement des informations à grande échelle en les regroupant en variables nominales pour conditionner des modèles de downscaling statistique tels que des générateurs de temps ou des fonctions de transfert.

Dans un contexte de downscaling statistique, on utilise plutôt un cas limite des régimes de temps où chaque jour définit un régime de temps [BOÉ et al., 2006] : les analogues de circulation. De façon schématique, un modèle d'analogie détermine pour un jour pour lequel on cherche à downscaler une variable, dans une archive passée, le jour ayant la situation à grande échelle la plus proche du jour en question selon un critère de similarité ou de distance. Un aspect important dans ces méthodes analogues porte sur le choix de ce critère de similarité [MATULLA et al., 2008; GRENIER et al., 2013] et du domaine des prédicteurs [WETTERHALL et al., 2005]. Un problème majeur des méthodes analogues classiques est qu'elles ne peuvent pas générer de valeurs au-delà des bornes des valeurs observées et peuvent potentiellement manquer un signal de changement climatique.

### 3.2.3. Générateurs de temps (WGs)

Les générateurs de temps (ou générateurs stochastiques) permettent de générer des séquences de variables climatiques (telles que les précipitations et les températures) reproduisant certaines propriétés statistiques des observations [RICHARDSON, 1981; SEMENOV et al., 1998].

Dans un contexte de downscaling, ces modèles consistent essentiellement à simuler la variable d'intérêt  $Y$  conditionnellement à l'information grande échelle  $X$ , en modélisant des densités conditionnelles de  $Y|X = x$  [pdf, *cf.* SEMENOV & BARROW, 1997; SEMENOV et al., 1998; WILKS & WILBY, 1999; WILKS, 2010]. Le principe des premiers générateurs consistait à estimer les paramètres de la pdf de la variable à l'échelle locale proportionnels aux paramètres de la pdf à grande échelle [WILBY et al., 2002; WILKS, 2010]. Aujourd'hui, on privilégie plutôt une approche où ce sont les paramètres de la pdf conditionnelle qui sont directement des fonctions d'informations grandes échelles. Ces informations peuvent avoir différentes natures : elles peuvent être issues de régimes de temps [VRAC et al., 2007d], des indices de circulation [e.g., l'indice d'oscillation atlantique nord, NAO YANG et al., 2005] ou des variables physiques à grande échelle [BELLONE et al., 2000; CARREAU & VRAC, 2011; WILKS, 2012]. Ainsi, malgré des liens constants entre grande échelle et échelle locale, la non-stationnarité de la grande échelle est répercutée sur la petite échelle (dans un contexte de changement climatique).

Il existe également un ensemble de générateurs de temps où les régimes de temps servent à conditionner le modèle stochastique en fonction des situations à grande échelle [HUGHES et al. [1999] ; CHARLES et al. [2004] ; MEHROTRA & SHARMA [2005] ; GREENE et al. [2011] et AILLIOT et al., 2015 , pour un article de synthèse].

Dans ce type de modèle, comme pour les fonctions de transfert, il faut faire attention à ce que les liens entre les paramètres des distributions et l'information grande échelle restent valides en dehors de la plage des données de calibration. Dans le cas contraire, les modèles peuvent générer des valeurs irréalistes.

#### 3.2.4. Correction de biais - MOS

Les familles de modèles précédemment présentées nécessitent une synchronicité temporelle entre les données à grande échelle et à l'échelle locale pour que ces modèles puissent être calibrés. Dans la littérature on y fait référence sous le nom de downscaling "Perfect-prog" [PP, KLEIN et al., 1959 ]. La famille de modèles regroupant toutes les méthodes de correction de biais (ou en anglais, Model output statistics, MOS) est assez différente par essence. En effet, ce genre de modèles relie directement les sorties de modèles aux observations et ne nécessite pas de calibration à partir de réanalyses. Généralement, MOS a pour but de relier des propriétés statistiques telles que la moyenne, la variance ou la fonction de répartition (en anglais, cumulative distribution function, CDF).

Dans un contexte de réduction d'échelle, des méthodes simples consistent à corriger uniquement le biais moyen [e.g. GUTMANN et al., 2011 ], d'autres plus sophistiquées corrigent les biais en termes de quantiles [e.g., AMENGUAL et al., 2011 par des correspondances de quantiles] ou bien encore en termes de CDFs [e.g., "cumulative distribution function transform", CDF-t VRAC et al., 2012 ; PIANI et al., 2010 par la définition d'une fonction de transfert de toute la distribution]. Plusieurs méthodes ont été testées et comparées dans GUDMUNDSSON et al. [2012]. Il faut néanmoins faire attention à l'utilisation de ce type de méthode dans un contexte de downscaling. En effet, la qualité de l'évolution temporelle des corrections/simulations est profondément liée à la qualité de l'évolution des données à grande échelle [COIFFIER, 2011]. Une hypothèse importante pour les méthodes de correction de biais qui ne sont pas de type CDF-t consiste à supposer que le biais en terme de distribution (de quantiles) est constant.

#### 3.2.5. Modélisation spatiale et downscaling

L'analyse spatiale et la modélisation spatiale ont pour but d'établir, à partir de bases de données incomplètes et de connaissances plus ou moins étendues sur les processus, les caractéristiques spatiales et les dynamiques spatio-temporelles de différents systèmes (hydrologique, écologique, agricole...). À partir de cela, il est possible d'en construire des représentations et des modèles utilisables à des fins de connaissance et de gestion. L'appréhension de l'organisation spatiale des systèmes est importante pour comprendre leur fonctionnement, qu'il s'agisse de dynamiques propres à l'environnement, de dynamiques socio-économiques ou de leurs interactions. Ainsi l'analyse et la modélisation spatiale dépendent grandement du domaine spatial considéré et du problème scientifique traité.

Une mouvance parmi les modèles de réduction d'échelle statistique a également pour but d'assurer une cohérence spatiale dans les simulations issues des SDMs. Parmi les quatre familles de SDMs

précédemment présentées, les modèles issus de la famille WTs, les analogues en particulier, permettent par définition de garder cette cohérence. Parmi les autres familles, les WGs proposent également un cadre favorable à la modélisation spatiale [BARDOSSY & PLATE, 1992; AILLIOT et al., 2015]. Ce manuscrit contribuera à cette catégorie de modèles. Les modèles MOS réalisant généralement une correction univariée ne conservent pas forcément la structure spatiale des observations dans les simulations [VRAC et al., 2012]. De plus, l'utilisation de telles méthodes pour le downscaling peut introduire des artefacts dans la structure spatiale des précipitations [MARAUN, 2013]. Cependant, une méthode a été mise en place dans VRAC & FRIEDERICHS [2015] pour corriger les biais tout en gardant la structure spatiale des données de référence.

### **3.3. Hypothèses implicites et limitations des modèles de régionalisation statistique**

Nous nous devons ici de préciser les limitations et hypothèses auxquelles sont soumis les modèles de régionalisation statistique.

La résolution des simulations issues des modèles de downscaling dépend en général de celle des observations et il n'est en général pas possible de simuler des variables à une résolution plus fine que celle des observations. Néanmoins, le cadre théorique de la modélisation spatiale permet de générer des données à des résolutions plus fines. Par exemple, le modèle GLIMCLIM développé par CHANDLER [2002] peut en théorie réaliser un downscaling à partir de stations et générer des simulations à une résolution plus fine que celle de jeux de données d'observations grillées ayant les résolutions les plus fines. C'est une piste que nous allons exploiter dans la suite de ce manuscrit (*cf.* CHAPITRE IV).

Il se pose également la question du choix de l'information à grande échelle à fournir aux différentes familles de modèles. En effet, il est nécessaire de choisir les prédictors pertinents pour la variable à modéliser par les modèles de réduction d'échelle. Cet aspect est relativement peu discuté dans ce manuscrit mais reste absolument décisif pour toute application efficace de downscaling. Au CHAPITRE II, nous avons mis en place une procédure de sélection d'un certain nombre de prédictors en climat récent. Mais, il se peut que ces variables ne soient plus valables dans un contexte de projections futures issues des GCMs. Il existe des hypothèses sous-jacentes à toute application de modèles de réduction d'échelle statistique en contexte de changement climatique [HEWITSON & CRANE, 1996; VRAC, 2012] :

- A. les liens établis (ou les modèles calibrés) – en contexte de climat présent ou passé récent – entre la grande échelle et la petite échelle restent valides en climat modifié ;
- B. les prédictors représentent adéquatement le signal du changement climatique ;
- C. les variables à grande échelle sont correctement représentées et pertinentes aussi bien dans les GCMs que dans les réanalyses.

Bien que ces hypothèses soient rarement évaluées avant d'appliquer la réduction d'échelle, il existe des standards pour évaluer la capacité des SDMs à reproduire des observations quand ils sont calibrés puis forcés par des réanalyses [HUTH, 1999; VRAC et al., 2007d] ou par des simulations CTRL des GCMs [WILBY & WIGLEY, 2000; CHARLES et al., 2004]. D'autres approches ont été testées pour

valider l'hypothèse A. de robustesse dans le temps en comparant des projections futures de SDMs avec celles de GCMs [FRÍAS et al., 2006] ou de RCMs [WOOD et al., 2004 ; HAYLOCK et al., 2006]. VRAC et al. [2007a] ont aussi développé une méthode d'évaluation des SDMs en climat CTRL (réanalyses vs. GCM) et en climat futur pour lequel les projections futures des RCMs sont considérées comme des pseudo-observations auxquelles on compare les projections issues des SDMs [cf. GAITAN et al., 2014 ; EDEN et al., 2015 pour des applications].

Il faut souligner que dans les travaux qui suivront, il n'est en aucun cas question d'opposer les deux approches de régionalisation dynamique et statistique. Ces approches sont complémentaires car elles se fournissent des informations mutuellement. Les RCMs génèrent par construction des simulations contraintes du point de vue spatial grâce à la résolution des équations de la dynamique. Elles permettent ainsi d'expliquer d'un point de vue physique les structures spatiales des précipitations (par exemple, une structure de type convective) et aident ainsi à la sélection de prédicteurs pertinents. Réciproquement, les liens statistiques établis par les SDMs permettent de quantifier la contribution plus ou moins importantes des différents prédicteurs aux variables à l'échelle locale et apportent potentiellement une aide pour la résolution et la paramétrisation de la physique dans les modèles.

Notons qu'ici nous aborderons le downscaling d'un point de vue spatial uniquement. Il existe aussi des modèles de réduction d'échelle temporelle en passant par exemple d'une résolution journalière à horaire [e.g. ALLARD & BOUROTTE, 2015 ; WILLEMS & VRAC, 2011 ; MEZGHANI & HINGRAY, 2009 ].

## 4. Cadre et objectifs de la thèse

### 4.1. Questionnement scientifique

#### 4.1.1. Intercomparaisons

Nous venons d'évoquer les différentes approches de modèles de régionalisation du climat. Nous avons également évoqué quelques initiatives de recherche coordonnées visant à comparer différents modèles de downscaling mais ces dernières donnaient clairement la priorité aux modèles dynamiques. Il existe néanmoins quelques intercomparaisons en climat présent et/ou futur portant uniquement sur les SDMs [e.g. WILBY & WIGLEY, 1997 ; HARPHAM & WILBY, 2005 ; BÜRGER et al., 2012b ; BÜRGER et al., 2012a ; GAITAN et al., 2014 ] ou incluant des RCMs aussi bien que des SDMs [e.g. HAYLOCK et al., 2006 ; SCHMIDLI et al., 2007 ].

Dans ces études, il manque en général soit les RCMs et/ou une ou plusieurs familles de SDMs. Et même dans le cas où toutes les catégories d'approches sont représentées dans le panel de modèles, les modèles se différencient soit par une origine différente des prédicteurs (en termes de variables ou de base de données), soit par la résolution des simulations [e.g. SCHMIDLI et al., 2007 ]. Une partie des travaux menés dans cette thèse répondra à cette question : **comment comparer les modèles en les considérant de manière aussi équitable que possible ?** Ceci permettra à terme de mettre en évidence les avantages et inconvénients des différentes approches en vu d'améliorations potentielles. De plus, on sera en mesure de fournir des simulations statistiques comparables aux simulations dynamiques. Pour cela on se placera dans le contexte de l'initiative CORDEX [GIORGI et al., 2009].

#### 4.1.2. Influence des biais dans les prédicteurs

Parmi les hypothèses implicites nécessaires à l'application des modèles de downscaling statistique, on retrouve deux hypothèses importantes concernant les prédicteurs. En particulier, nous supposons que la représentation des variables de circulation est aussi réaliste dans les GCMs que dans les réanalyses (hypothèse C.). Cette hypothèse implicite est absolument nécessaire puisque la plupart des modèles (i.e., les PP) de downscaling statistique sont d'abord calibrés à partir des réanalyses, considérées comme la “meilleure image” de la circulation à grande échelle. Les projections sur les périodes historiques et futures sont ensuite réalisées à partir de ces calibrations. Il faut garder à l'esprit que ceci ne concerne pas les modèles MOS puisque cette catégorie de modèles ne nécessite pas de calibration à l'aide des réanalyses (*cf.* SECTION 3.2.4).

En cas d'invalidité de cette hypothèse, c'est à dire en cas de présence d'un biais dans les GCMs par rapport aux réanalyses, on peut se poser la question suivante : **Quelle est la sensibilité des modèles de réduction d'échelle aux biais des GCMs ?** Nous apporterons une réponse à cette question en quantifiant ce biais et mettant en place une procédure de correction de ce biais. Nous resterons dans le cadre CORDEX et nous nous intéresserons ici uniquement aux modèles de downscaling statistique.

#### 4.1.3. Non-stationnarité spatiale et temporelle

Dans un contexte de changement climatique, le climat est par définition non-stationnaire. Parmi les données actuellement disponibles, les GCMs sont les données permettant de caractériser ces changements dans le futur.

Une des hypothèses selon laquelle sont réalisés les modèles de réductions d'échelle spatiale repose sur l'établissement de liens de nature stationnaire entre la grande échelle et l'échelle locale (hypothèse A.). Malgré cela, dans les modèles de type WGs, nous sommes capable d'introduire de la non-stationnarité dans les paramètres des générateurs de temps en exprimant ces derniers en fonctions des variables à grande échelle reflétant un climat changeant (*cf.* SECTION 3.2.3). La non-stationnarité signifie un changement du climat dans le temps mais aussi dans l'espace.

La question qui se pose ici est la suivante : **Comment introduire cette non-stationnarité spatiale et temporelle dans un modèle de downscaling statistique ?** Pour répondre à cela nous nous placerons dans le cadre de la modélisation spatiale et dans un contexte de climat présent.

Non-stationnarité signifie aussi variabilité climatique. Celle-ci peut influencer notre perception du climat de tous les jours et notamment des saisons. Dans ce contexte, nous allons répondre à la question suivante : **existe-t-il une définition des saisons tenant compte de cette variabilité ?** Nous nous placerons alors dans une étude en définissant les saisons par des régimes de temps saisonniers dans un contexte de climat présent.

## 4.2. Objectifs de la thèse

Le **premier objectif de la thèse** est de mieux appréhender et utiliser les **modèles de réduction d'échelle** statistiques à l'échelle du continent européen. Nous chercherons pour cela à :

- *Objectif n°1.1* : comparer des modèles de régionalisation dynamique et statistique pour la précipitation par le biais d'un cadre d'évaluation dans un contexte de climat actuel ;
- *Objectif n°1.2* : étendre l'exercice d'intercomparaison à différents forçages climatiques issus des GCMs sur les périodes CTRL et futures pour évaluer la sensibilité des modèles statistiques (uniquement ici) aux biais des GCMs et l'apport et l'impact d'une procédure de correction de ces biais.

La démarche permettra de disposer d'indicateurs statistiques utiles pour des applications en :

- climatologie : afin d'identifier les faiblesses des différents types de modèles en vue d'une amélioration ;
- modélisation d'impacts : pour choisir les données répondant à la nature de l'étude.

Le **second objectif de la thèse** (*Objectif n°2*) est de développer un **modèle de réduction d'échelle** qui prenne en compte la **non-stationnarité** du climat et ce de manière **spatialement cohérente**. Le travail sera effectué sur la zone méditerranéenne française. Les questions suivantes guideront le cheminement dans le développement :

- l'apport de non-stationnarité temporelle dans un modèle spatial,
- l'apport des covariables spatiales dans un contexte de downscaling.

Nous nous appuyerons ici sur des outils statistiques utilisés dans le premier objectif pour introduire la non-stationnarité dans le modèle et nous nous placera dans un contexte de processus aléatoire pour répondre à l'exigence d'une bonne cohérence spatiale.

Le **troisième objectif** (*Objectif n°3*) est d'établir une définition des **saisons** à partir d'une modélisation des régimes de circulation atmosphérique. Nous obtenons un **modèle** statistique par régime. Le travail sera effectué sur la zone Atlantique Nord.

La modélisation utilisée permettra des applications pour :

- l'établissement de régimes saisonniers ou intra-saisonniers pour d'autres variables, régions ou périodes de temps ;
- une utilisation originale des prévisions saisonnières à court terme.



## 5. Plan du manuscrit

Le fil conducteur de ce document sera la régionalisation du climat et en particulier la réduction d'échelle statistique. La région d'intérêt sera quasi-exclusivement l'Europe et certaines régions Européennes.

Compte tenu de la variété des modèles de réduction d'échelle, nous travaillerons en grande partie uniquement sur les précipitations afin de répondre au mieux aux différents objectifs. Nous nous attacherons donc à établir une méthodologie permettant de discriminer les différents modèles de manière aussi objective que possible. Cet aspect sera l'objet du CHAPITRE II et répondra à l'*Objectif n°1.1*. Par ailleurs, nous étudierons la sensibilité des modèles statistiques pour différents forçages climatiques. Ceci reposera sur le travail développé au CHAPITRE III pour répondre à l'*Objectif n°1.2*.

Dans la partie développement, la priorité sera donnée aux modèles spatiaux de type stochastique. Les bases théoriques et les différentes étapes du développement seront posées dans le CHAPITRE IV, nous répondrons ainsi à l'*Objectif n°2*.

Ensuite, une réponse sera apportée à l'*Objectif n°3* par un travail sur les régimes saisonniers mené au CHAPITRE V dans lequel nous donnerons une définition des saisons à l'aide d'une modélisation de régimes de circulation atmosphérique. Ce travail donnera certaines perspectives en soit mais aussi des perspectives que nous pourrons mettre en relation avec les chapitres précédents.

Le CHAPITRE VI fera un bilan des travaux et de leurs résultats et précisera certaines perspectives.

## Références Bibliographiques du Chapitre I

- AILLIOT, Pierre, ALLARD, Denis, MONBET, Valérie & NAVEAU, Philippe [2015]. “Stochastic weather generators : an overview of weather type models”. *Journal de la Société Française de Statistique*. Vol. 156. no. 1, p. 101–113.
- ALLARD, Denis & BOUROTTE, Marc [2015]. “Disaggregating daily precipitations into hourly values with a transformed censored latent Gaussian process”. *Stochastic Environmental Research and Risk Assessment*. Vol. 29. no. 2, p. 453–462.
- AMENGUAL, A., HOMAR, V., ROMERO, R., ALONSO, S. & RAMIS, C. [2011]. “A Statistical Adjustment of Regional Climate Model Outputs to Local Scales : Application to Platja de Palma, Spain”. *Journal of Climate*. Vol. 25. no. 3, p. 939–957.
- BARDOSSY, Andras & PLATE, Erich J. [1992]. “Space-time model for daily rainfall using atmospheric circulation patterns”. *Water Resources Research*. Vol. 28. no. 5, p. 1247–1259.
- BARNSTON, Anthony G. & LIVEZEY, Robert E. [1987]. “Classification, Seasonality and Persistence of Low-Frequency Atmospheric Circulation Patterns”. *Monthly Weather Review*. Vol. 115. no. 6, p. 1083–1126.
- BELLONE, Enrica, HUGHES, James P. & GUTTORP, Peter [2000]. “A hidden Markov model for downscaling synoptic atmospheric patterns to precipitation amounts”. *Journal of Hydrology*. Vol. 15. no. 1, p. 1–12.
- BINDOFF, N.L., STOTT, P.A., ACHUTARAO, K.M., ALLEN, M.R., GILLET, N., GUTZLER, D., HANSINGO, K., HEGERL, G., HU, Y., JAIN, S., MOKHOV, I.I., OVERLAND, J., PERLWITZ, J., SEBBARI, R. & ZHANG, X. [2013]. “Detection and Attribution of Climate Change : from Global to Regional”. *Climate Change 2013 : The Physical Science Basis. Contribution of Working Group I to the Fifth Assessment Report of the Intergovernmental Panel on Climate Change*. Sous la dir. de T.F. STOCKER, D. QIN, G.-K. PLATTNER, M. TIGNOR, S.K. ALLEN, J. BOSCHUNG, A. NAUELS, Y. XIA, V. BEX & P.M. MIDGLEY. Cambridge, United Kingdom & New York, NY, USA : Cambridge University Press. Chap. 10, 867–952.
- BOÉ, J., TERRAY, L., HABETS, F. & MARTIN, E. [2006]. “A simple statistical-dynamical downscaling scheme based on weather types and conditional resampling”. *Journal of Geophysical Research : Atmospheres*. Vol. 111. no. D23. D23106, n/a–n/a.
- BÜRGER, G., SOBIE, S. R., CANNON, A. J., WERNER, A. T. & MURDOCK, T. Q. [2012a]. “Downscaling Extremes : An Intercomparison of Multiple Methods for Future Climate”. *Journal of Climate*. Vol. 26. no. 10, p. 3429–3449.
- BÜRGER, G., MURDOCK, T. Q., WERNER, A. T., SOBIE, S. R. & CANNON, A. J. [2012b]. “Downscaling Extremes—An Intercomparison of Multiple Statistical Methods for Present Climate”. *Journal of Climate*. Vol. 25. no. 12.
- CANNON, Alex J [2011]. “Quantile regression neural networks : Implementation in R and application to precipitation downscaling”. *Computers & Geosciences*. Vol. 37. no. 9, p. 1277–1284.
- CARREAU, Julie & VRAC, Mathieu [2011]. “Stochastic downscaling of precipitation with neural network conditional mixture models”. *Water Resources Research*. Vol. 47. no. 10. W10502, n/a–n/a.
- CASSOU, C. [2008]. “Intraseasonal interaction between the Madden–Julian Oscillation and the North Atlantic Oscillation”. *Nature*. Vol. 455, p. 523–527.
- CHANDLER, R. E. [2002]. “GLIMCLIM : generalized linear modelling for daily climate time series—user guide.” *Tech rep. Department of Statistical Science, University College London*.
- CHANDLER, Richard E. [2005]. “On the use of generalized linear models for interpreting climate variability”. *Environmetrics*. Vol. 16. no. 7, p. 699–715.
- CHARLES, Stephen P., BATES, Bryson C., SMITH, Ian N. & HUGHES, James P. [2004]. “Statistical downscaling of daily precipitation from observed and modelled atmospheric fields”. *Hydrological Processes*. Vol. 18. no. 8, p. 1373–1394.
- CHRISTENSEN, JensHesselbjerg & CHRISTENSEN, OleBøssing [2007]. “A summary of the PRUDENCE model projections of changes in European climate by the end of this century”. *Climatic Change*. Vol. 81. no. 1, p. 7–30.
- COIFFIER, Jean [2011]. “Fundamentals of Numerical Weather Prediction”. Cambridge Books Online. Cambridge University Press.
- COLES, S. [2001]. “An introduction to statistical modeling of extreme values”. London ; New York : Springer.
- CONWAY, D, WILBY, RL & JONES, PD [1996]. “Precipitation and air flow indices over the British Isle”. *Climate Research*. Vol. 7. no. 2, p. 169–183.
- COOLEY, D. & SAIN, S.R. [2010]. “Spatial Hierarchical Modeling of Precipitation Extremes From a Regional Climate Model”. *Journal of Agricultural, Biological, and Environmental Statistics*. Vol. 15, p. 381–402.
- DEE, D. P., UPPALA, S. M., SIMMONS, A. J., BERRISFORD, P., POLI, P., KOBAYASHI, S., ANDRAE, U., BALMASEDA, M. A., BALSAMO, G., BAUER, P., BECHTOLD, P., BELJAARS, A. C. M., BERG, L. van de, BIDLOT, J., BORMANN, N., DELSOL, C., DRAGANI, R., FUENTES, M., GEER, A. J., HAIMBERGER, L.,

- HEALY, S. B., HERSBACH, H., HÓLM, E. V., ISAKSEN, L., KÅLLBERG, P., KÖHLER, M., MATRICARDI, M., McNALLY, A. P., MONGE-SANZ, B. M., MORCRETTE, J.-J., PARK, B.-K., PEUBEY, C., ROSNAY, P. de, TAVOLATO, C., THÉPAUT, J.-N. & VITART, F. [2011]. "The ERA-Interim reanalysis : configuration and performance of the data assimilation system". *Quarterly Journal of the Royal Meteorological Society*. Vol. 137. no. 656, p. 553–597.
- DEE, D. P., BALMASEDA, M., BALSAMO, G., ENGELEN, R., SIMMONS, A. J. & THÉPAUT, J.-N. [2014]. "The ERA-Interim reanalysis : configuration and performance of the data assimilation system". *Bulletin of the American Meteorological Society*. Vol. 95. no. 8, p. 1235–1248.
- DEMPSTER, A., LAIRD, N. & RUBIN, D. [1977]. "Maximum likelihood from incomplete data via the EM algorithm". *J. Royal. Stat. Soc., Ser. B*. Vol. 39, p. 1–38.
- DIDAY, Edwin [1974]. "Optimization in non-hierarchical clustering". *Pattern Recognition*. Vol. 6. no. 1, p. 17–33.
- DÉQUÉ, M. & PIEDELIEVRE, J.Ph. [1995]. "High resolution climate simulation over Europe". *Climate Dynamics*. Vol. 11. no. 6, p. 321–339.
- DÉQUÉ, Michel [2007]. "Frequency of precipitation and temperature extremes over France in an anthropogenic scenario : Model results and statistical correction according to observed values". *Global and Planetary Change*. Vol. 57. no. 1–2, p. 16–26.
- EDEN, Jonathan M., WIDMANN, Martin, MARAUN, Douglas & VRAC, Mathieu [2015]. "Comparison of GCM- and RCM-simulated precipitation following stochastic postprocessing". *Journal of Geophysical Research : Atmospheres*. Vol. 119. no. 19, p. 11,040–11,053.
- FRIEDERICH, P. & HENSE, A. [2007]. "Statistical Downscaling of Extreme Precipitation Events Using Censored Quantile Regression". *Monthly Weather Review*. Vol. 135. no. 6, p. 2365–2378.
- FRÍAS, M. D., ZORITA, E., FERNÁNDEZ, J. & RODRÍGUEZ-PUEBLA, C. [2006]. "Testing statistical downscaling methods in simulated climates". *Geophysical Research Letters*. Vol. 33. no. 19.
- FU, Congbin, WANG, Shuyu, XIONG, Zhe, GUTOWSKI, William J., LEE, Dong-Kyou, MCGREGOR, John L., SATO, Yasuo, KATO, Hisashi, KIM, Jeong-Woo & SUH, Myoung-Seok [2005]. "Regional Climate Model Intercomparison Project for Asia". *Bulletin of the American Meteorological Society*. Vol. 86. no. 2, p. 257–266.
- GAITAN, CarlosF., HSIEH, WilliamW. & CANNON, AlexJ. [2014]. "Comparison of statistically downscaled precipitation in terms of future climate indices and daily variability for southern Ontario and Quebec, Canada". *Climate Dynamics*. P. 1–17.
- GIORGI, F., JONES, C. & ASRAR, G. R. [2009]. "Addressing climate information needs at the regional level : the CORDEX framework." *Bulletin of the World Meteorologic Organization*. Vol. 58(3), p. 175–183.
- GOODESS, CM & JONES, PD [2002]. "Links between circulation and changes in the characteristics of Iberian rainfall". *International Journal of Climatology*. Vol. 22. no. 13, p. 1593–1615.
- GREENE, Arthur M., ROBERTSON, Andrew W., SMYTH, Padhraic & TRIGLIA, Scott [2011]. "Downscaling projections of Indian monsoon rainfall using a non-homogeneous hidden Markov model". *Quarterly Journal of the Royal Meteorological Society*. Vol. 137. no. 655, p. 347–359.
- GRENIER, Patrick, PARENT, Annie-Claude, HUARD, David, ANCTIL, François & CHAUMONT, Diane [2013]. "An Assessment of Six Dissimilarity Metrics for Climate Analogs". *Journal of Applied Meteorology and Climatology*. Vol. 52. no. 4, p. 733–752.
- GUDMUNDSSON, L., BRENNES, J. B., HAUGEN, J. E. & ENGEN-SKAUGEN, T. [2012]. "Technical Note : Downscaling RCM precipitation to the station scale using statistical transformations - a comparison of methods". *Hydrology and Earth System Sciences*. Vol. 16. no. 9, p. 3383–3390.
- GUTMANN, Ethan D., RASMUSSEN, Roy M., LIU, Changhai, IKEDA, Kyoko, GOCHIS, David J., CLARK, Martyn P., DUDHIA, Jimmy & THOMPSON, Gregory [2011]. "A Comparison of Statistical and Dynamical Downscaling of Winter Precipitation over Complex Terrain". *Journal of Climate*. Vol. 25. no. 1, p. 262–281.
- HARPHAM, Colin & WILBY, Robert L. [2005]. "Multi-site downscaling of heavy daily precipitation occurrence and amounts". *Journal of Hydrology*. Vol. 312. no. 1–4, p. 235–255.
- HAYLOCK, M. R., HOFSTRA, N., KLEIN TANK, A. M. G., KLOK, E. J., JONES, P. D. & NEW, M. [2008]. "A European daily high-resolution gridded data set of surface temperature and precipitation for 1950–2006". *Journal of Geophysical Research : Atmospheres*. Vol. 113. no. D20.
- HAYLOCK, Malcolm R., CAWLEY, Gavin C., HARPHAM, Colin, WILBY, Rob L. & GOODESS, Clare M. [2006]. "Downscaling heavy precipitation over the United Kingdom : a comparison of dynamical and statistical methods and their future scenarios". *International Journal of Climatology*. Vol. 26. no. 10, p. 1397–1415.
- HEWITSON, B. C. & CRANE, R. G. [2006]. "Consensus between GCM climate change projections with empirical downscaling : precipitation downscaling over South Africa". *International Journal of Climatology*. Vol. 26. no. 10, p. 1315–1337.
- HEWITSON, BC & CRANE, RG [1996]. "Climate downscaling : techniques and application". *Climate Research*. Vol. 7. no. 2, p. 85–95.

- HEWITT, Chris D. [2004]. “Ensembles-based predictions of climate changes and their impacts”. *Eos, Transactions American Geophysical Union*. Vol. 85. no. 52, p. 566.
- HOUDIN, Frédéric, MUSAT, Ionela, BONY, Sandrine, BRACONNOT, Pascale, CODRON, Francis, DUFRESNE, Jean-Louis, FAIRHEAD, Laurent, FILIBERTI, Marie-Angèle, FRIEDLINGSTEIN, Pierre, GRANDPEIX, Jean-Yves, KRINNER, Gerhard, LEVAN, Phu, LI, Zhao-Xin & LOTT, François [2006]. “The LMDZ4 general circulation model : climate performance and sensitivity to parametrized physics with emphasis on tropical convection”. *Climate Dynamics*. Vol. 27. no. 7-8, p. 787–813.
- HUGHES, J. P., GUTTORP, P & CHARLES, S. P. [1999]. “A non-homogeneous hidden Markov model for precipitation occurrence”. *Journal of the Royal Statistical Society : Series C (Applied Statistics)*. Vol. 48. no. 1, p. 15–30.
- HUTH, Radan [1999]. “Statistical downscaling in central Europe : evaluation of methods and potential predictors”. *Climate Research*. Vol. 13. no. 2, p. 91–101.
- KALNAY, E., KANAMITSU, M., KISTLER, R., COLLINS, W., DEAVEN, D., GANDIN, L., IREDELL, M., SAHA, S., WHITE, G., WOOLLEN, J., ZHU, Y., CHELLIAH, M., EBISUZAKI, W., W. HIGGINS, JANOWIAK, J., MO, K. C., ROPELEWSKI, C., WANG, J., LEETMAA, A., REYNOLDS, R., JENNE, R. & JOSEPH, D. [1996]. “The NCEP/NCAR 40-Year Reanalysis Project”. *Bulletin of the American Meteorological Society*. Vol. 77 (3), p. 437–471.
- KLEIN, William H., LEWIS, Billy M. & ENGER, Isadore [1959]. “OBJECTIVE PREDICTION OF FIVE-DAY MEAN TEMPERATURES DURING WINTER”. *Journal of Meteorology*. Vol. 16. no. 9, p. 972–682.
- KLEIN TANK, A. M. G., WIJNGAARD, J. B., KÖNNEN, G. P., BÖHM, R., DEMARÉE, G., GOCHEVA, A., MILETA, M., PASHIARDIS, S., HEJKRLIK, L., KERN-HANSEN, C., HEINO, R., BESSEMOULIN, P., MÜLLER-WESTERMEIER, G., TZANAKOU, M., SZALAI, S., PÁLSDÓTTIR, T., FITZGERALD, D., RUBIN, S., CAPALDO, M., MAUGERI, M., LEITASS, A., BUKANTIS, A., ABERFELD, R., ENGELEN, A. F. V. van, FORLAND, E., MIETUS, M., COELHO, F., MARES, C., RAZUVAEV, V., NIEPLOVA, E., CEGNAR, T., ANTONIO LÓPEZ, J., DAHLSTRÖM, B., MOBERG, A., KIRCHHOFFER, W., CEYLAN, A., PACHALIUK, O., ALEXANDER, L. V. & PETROVIC, P. [2002]. “Daily dataset of 20th-century surface air temperature and precipitation series for the European Climate Assessment”. *International Journal of Climatology*. Vol. 22. no. 12, p. 1441–1453.
- KOHONEN, T [1981]. “Construction of Similarity Diagrams for Phonemes by a Self-Organizing Algorithm”. Technical Report TKKjVFjVA463, Helsinki University of Technology, Finland.
- LAPRISE, R., ELÍA, R. de, CAYA, D., BINER, S., LUCAS-PICHER, P., DIACONESCU, E., LEDUC, M., ALEXANDRU, A. & SEPAROVIC, L. [2008]. “Challenging some tenets of Regional Climate Modelling”. *Meteorology and Atmospheric Physics*. Vol. 100. no. 1-4, p. 3–22.
- LEVAVASSEUR, G., VRAC, M., ROCHE, D. M., PAILLARD, D., MARTIN, A. & VANDENBERGHE, J. [2011]. “Present and LGM permafrost from climate simulations : contribution of statistical downscaling”. *Climate of the Past*. Vol. 7. no. 4, p. 1225–1246.
- MACHENHAUER, B., WINDELBAND, M., BOTZET, M., HESSELBJERG, J., DÉQUÉ, M., JONES, G.R., RUTI, P.M. & VISCONTI, G. [1998]. “Validation and Analysis of Regional Present-day Climate and Climate Change Simulations over Europe”. *Max-Planck Institute of Meteorology Report No. 275, 87pp.*
- MARAUN, Douglas [2013]. “Bias Correction, Quantile Mapping, and Downscaling : Revisiting the Inflation Issue”. *Journal of Climate*. Vol. 26. no. 6, p. 2137–2143.
- MATULLA, C., ZHANG, X., WANG, X.L., WANG, J., ZORITA, E., WAGNER, S. & STORCH, H. von [2008]. “Influence of similarity measures on the performance of the analog method for downscaling daily precipitation”. *Climate Dynamics*. Vol. 30. no. 2-3, p. 133–144.
- MEARNS, L.O., SAIN, S., LEUNG, L.R., BUKOVSKY, M.S., MCGINNIS, S., BINER, S., CAYA, D., ARMITT, R.W., GUTOWSKI, W., TAKLE, E., SNYDER, M., JONES, R.G., NUNES, A.M.B., TUCKER, S., HERZMANN, D., MCDANIEL, L. & SLOAN, L. [2013]. “Climate change projections of the North American Regional Climate Change Assessment Program (NARCCAP)”. *Climatic Change*. Vol. 120. no. 4, p. 965–975.
- MEHROTRA, R. & SHARMA, Ashish [2005]. “A nonparametric nonhomogeneous hidden Markov model for downscaling of multisite daily rainfall occurrences”. *Journal of Geophysical Research : Atmospheres*. Vol. 110. no. D16. D16108, n/a–n/a.
- MEZGHANI, A. & HINGRAY, B. [2009]. “A combined downscaling-disaggregation weather generator for stochastic generation of multisite hourly weather variables over complex terrain : Development and multi-scale validation for the Upper Rhone River basin”. *Journal of Hydrology*. Vol. 377. no. 3–4, p. 245 –260.
- MICHELANGELO, P.-A., VAUTARD, R. & LEGRAS, B. [1995]. “Weather regimes : Recurrence and quasi-stationarity”. *J. Atmos. Sci.* Vol. 52, p. 1237–1256.
- NING, Liang, MANN, Michael E., CRANE, Robert & WAGENER, Thorsten [2012]. “Probabilistic Projections of Climate Change for the Mid-Atlantic Region of the United States : Validation of Precipitation Downscaling during the Historical Era\*”. *Journal of Climate*. Vol. 25. no. 2, p. 509–526.

- PAGÉ, Christian, TERRAY, Laurent & BOÉ, Julien [2010]. “dsclim : A software package to downscale climate scenarios at regional scale using a weather-typing based statistical methodology”. *Climate Modelling and Global Change TR/CMGC/09/21. CERFACS*.
- PANTHOU, G., VISCHÉL, T., LEBEL, T., BLANCHET, J., QUANTIN, G. & ALI, A. [2012]. “Extreme rainfall in West Africa : A regional modeling”. *Water Resources Research*. Vol. 48. no. 8, p. 1–19.
- PIANI, C., WEEDON, G.P., BEST, M., GOMES, S.M., VITERBO, P., HAGEMANN, S. & HAERTER, J.O. [2010]. “Statistical bias correction of global simulated daily precipitation and temperature for the application of hydrological models”. *Journal of Hydrology*. Vol. 395. no. 3–4, p. 199–215.
- RIBES, Aurélien, AZAÏS, Jean-Marc & PLANTON, Serge [2010]. “A method for regional climate change detection using smooth temporal patterns”. *Climate Dynamics*. Vol. 35. no. 2-3, p. 391–406.
- RICHARDSON, C. W. [1981]. “Stochastic simulation of daily precipitation, temperature, and solar radiation”. *Water Resources Research*. Vol. 17. no. 1, p. 182–190.
- RUMMUKAINEN, Markku [2010]. “State-of-the-art with regional climate models”. *Wiley Interdisciplinary Reviews : Climate Change*. Vol. 1. no. 1, p. 82–96.
- SACHINDRA, D. A., HUANG, F., BARTON, A. F. & PERERA, B. J. C. [2014]. “Multi-model ensemble approach for statistically downscaling general circulation model outputs to precipitation”. *Quarterly Journal of the Royal Meteorological Society*. Vol. 140. no. 681, p. 1161–1178.
- SCHMIDLI, J., GOODESS, C. M., FREI, C., HAYLOCK, M. R., HUNDECHA, Y., RIBALAYGUA, J. & SCHMITH, T. [2007]. “Statistical and dynamical downscaling of precipitation : An evaluation and comparison of scenarios for the European Alps”. *Journal of Geophysical Research : Atmospheres*. Vol. 112. no. D4.
- SEMENOV, Mikhail A., BROOKS, Roger J., BARROW, Elaine M. & RICHARDSON, Clarence W. [1998]. “Comparison of the WGEN and LARS-WG stochastic weather generators for diverse climates”. *Climate Research*. Vol. 10. no. 2, p. 95–107.
- SEMENOV, Mikhaila. & BARROW, Elainem. [1997]. “Use of a stochastic weather generator in the development of climate change scenarios”. *Climatic Change*. Vol. 35. no. 4, p. 397–414.
- SKAMAROCK, WC, KLEMP, JB, DUDHIA, J, GILL, DO, BARKER, DM, DUDA, MG, HUANG, XY, WANG, W & POWERS, JG [2008]. “A description of the advanced research wrf version 3”. *Technical Report, NCAR*.
- STORCH, H. v. (Hans von) & ZWIERS, Francis W [2001]. “Statistical analysis in climate research”. English. 1st pbk. ed. (with corrections). Originally published : 1999. This is the paperback edition , with corrections. Cambridge, UK ; New York : Cambridge University Press.
- TAKLE, Eugene S., GUTOWSKI, William J., ARMITT, Raymond W., PAN, Zaitao, ANDERSON, Christopher J., SILVA, Renato Ramos da, CAYA, Daniel, CHEN, Shyh-Chin, GIORGI, F., CHRISTENSEN, Jens Hesselbjerg, HONG, Song-You, JUANG, Hann-Ming Henry, KATZFEY, Jack, LAPENTA, William M., LAPRISE, Rene, LISTON, Glen E., LOPEZ, Philippe, MCGREGOR, John, PIELKE, Roger A. & ROADS, John O. [1999]. “Project to Intercompare Regional Climate Simulations (PIRCS) : Description and initial results”. *Journal of Geophysical Research : Atmospheres*. Vol. 104. no. D16, p. 19443–19461.
- VAUTARD, Robert [1990]. “Multiple weather regimes over the North Atlantic : Analysis of precursors and successors”. *Monthly weather review*. Vol. 118. no. 10, p. 2056–2081.
- VIGAUD, N., VRAC, M. & CABALLERO, Y. [2013]. “Probabilistic downscaling of GCM scenarios over southern India”. *International Journal of Climatology*. Vol. 33. no. 5, p. 1248–1263.
- VRAC, M. & YIOU, P. [2010]. “Weather regimes designed for local precipitation modeling : Application to the Mediterranean basin”. *J. Geophys. Res.*. Vol. 115, D12103.
- VRAC, M., STEIN, M. L., HAYHOE, K. & LIANG, X.-Z. [2007a]. “A general method for validating statistical downscaling methods under future climate change”. *Geophysical Research Letters*. Vol. 34. no. 18.
- VRAC, M., MARBAIX, P., PAILLARD, D. & NAVEAU, P. [2007c]. “Non-linear statistical downscaling of present and LGM precipitation and temperatures over Europe”. *Climate of the Past*. Vol. 3. no. 4, p. 669–682.
- VRAC, M., STEIN, M. L. & HAYHOE, K. [2007d]. “Statistical downscaling of precipitation through nonhomogeneous stochastic weather typing”. *Climate Research*. Vol. 34. no. 3, p. 169–184.
- VRAC, M., DROBINSKI, P., MERLO, A., HERRMANN, M., LAVAYSSE, C., LI, L. & SOMOT, S. [2012]. “Dynamical and statistical downscaling of the French Mediterranean climate : uncertainty assessment”. *Natural Hazards and Earth System Science*. Vol. 12. no. 9, p. 2769–2784.
- VRAC, Mathieu [2012]. “Modélisations statistiques à différentes échelles climatiques et environnementales”. “Habilitation à Diriger des Recherches” (HDR - Sciences de l’Environnement, UVSQ) – In Fench, p. 140.
- VRAC, Mathieu & FRIEDERICH, Petra [2015]. “Multivariate—Intervariable, Spatial, and Temporal—Bias Correction”. *Journal of Climate*. Vol. 28. no. 1, p. 218–237.
- WARD Jr, Joe H [1963]. “Hierarchical grouping to optimize an objective function”. *Journal of the American statistical association*. Vol. 58. no. 301, p. 236–244.
- WETTERHALL, Fredrik, HALLDIN, Sven & XU, Chong yu [2005]. “Statistical precipitation downscaling in central Sweden with the analogue method”. *Journal of Hydrology*. Vol. 306. no. 1–4, p. 174–190.

- WG1AR5IPCC [2013]. “Summary for Policymakers”. Climate Change 2013 : The Physical Science Basis. Contribution of Working Group I to the Fifth Assessment Report of the Intergovernmental Panel on Climate Change. Sous la dir. de T.F. STOCKER, D. QIN, G.-K. PLATTNER, M. TIGNOR, S.K. ALLEN, J. BOSCHUNG, A. NAUELS, Y. XIA, V. BEX & P.M. MIDGLEY. Cambridge, United Kingdom & New York, NY, USA : Cambridge University Press. Chap. SPM, 1–30.
- WG2AR5IPCC [2014]. “Climate Change 2014 : Impacts, Adaptation, and Vulnerability. Part A : Global and Sectoral Aspects. Contribution of Working Group II to the Fifth Assessment Report of the Intergovernmental Panel on Climate Change [Field, C.B., V.R. Barros, D.J. Dokken, K.J. Mach, M.D. Mastrandrea, T.E. Bilir, M. Chatterjee, K.L. Ebi, Y.O. Estrada, R.C. Genova, B. Girma, E.S. Kissel, A.N. Levy, S. MacCracken, P.R. Mastrandrea, and L.L. White (eds.)]” Cambridge, United Kingdom & New York, NY, USA : Cambridge University Press, p. 1132.
- WILBY, R.L. & WIGLEY, T.M.L. [1997]. “Downscaling general circulation model output : a review of methods and limitations”. *Progress in Physical Geography*. Vol. 21. no. 4, p. 530–548. eprint : <http://ppg.sagepub.com/content/21/4/530.full.pdf+html>.
- WILBY, R.L. & WIGLEY, T.M.L. [2000]. “Precipitation predictors for downscaling : observed and general circulation model relationships”. *International Journal of Climatology*. Vol. 20. no. 6, p. 641–661.
- WILBY, Robert L, DAWSON, Christian W & BARROW, Elaine M [2002]. “SDSM—a decision support tool for the assessment of regional climate change impacts”. *Environmental Modelling & Software*. Vol. 17. no. 2, p. 145–157.
- WILKS, D. S. & WILBY, R. L. [1999]. “The weather generation game : a review of stochastic weather models”. *Progress in Physical Geography*. Vol. 23. no. 3, p. 329–357. eprint : <http://ppg.sagepub.com/content/23/3/329.full.pdf+html>.
- WILKS, Daniel S. [2010]. “Use of stochastic weathergenerators for precipitation downscaling”. *Wiley Interdisciplinary Reviews : Climate Change*. Vol. 1. no. 6, p. 898–907.
- WILKS, Daniel S [2011]. “Statistical methods in the atmospheric sciences”. Vol. 100. Academic press.
- WILKS, Daniel S. [2012]. “Stochastic weather generators for climate-change downscaling, part II : multivariable and spatially coherent multisite downscaling”. *Wiley Interdisciplinary Reviews : Climate Change*. Vol. 3. no. 3, p. 267–278.
- WILLEMS, P. & VRAC, M. [2011]. “Statistical precipitation downscaling for small-scale hydrological impact investigations of climate change”. *Journal of Hydrology*. Vol. 402. no. 3–4, p. 193 –205.
- WOOD, A.W., LEUNG, L.R., SRIDHAR, V. & LETTENMAIER, D.P. [2004]. “Hydrologic Implications of Dynamical and Statistical Approaches to Downscaling Climate Model Outputs”. *Climatic Change*. Vol. 62. no. 1-3, p. 189–216.
- YANG, C., CHANDLER, R. E., ISHAM, V. S. & WHEATER, H. S. [2005]. “Spatial-temporal rainfall simulation using generalized linear models”. *Water Resources Research*. Vol. 41. no. 11, W11415.
- YIOU, P. & NOGAJ, M. [2004]. “Extreme climatic events and weather regimes over the North Atlantic : When and where?” : *Geophysical Research Letters*. Vol. 31. no. 7.
- ZORITA, Eduardo & STORCH, Hans von [1999]. “The Analog Method as a Simple Statistical Downscaling Technique : Comparison with More Complicated Methods”. *Journal of Climate*. Vol. 12. no. 8, p. 2474–2489.



# Intercomparaison de différentes approches de Régionalisation du climat dans un contexte de Climat présent.

Où l'on décrit un cadre d'intercomparaison de modèle de régionalisation et son application dans plusieurs contextes.

1. Introduction.....	26
2. Publication : Intercomparison of statistical and dynamical downscaling models under the EURO- and MED-CORDEX initiative framework : present climate evaluations.....	27
Résumé étendu . . . . .	27
1. Introduction . . . . .	31
2. Data and experimental setup . . . . .	36
3. Statistical and dynamical downscaling models . . . . .	39
4. Intercomparison results . . . . .	43
5. Conclusions and discussions . . . . .	52
3. Étude complémentaire concernant le choix du seuil.....	59
4. Perspectives.....	63
5. Synthèse des résultats.....	65



## 1. Introduction

Ce chapitre a pour but de réaliser une intercomparaison de modèles de régionalisation du climat aussi bien statistique (SDM) que dynamique (RCM) et ce de manière robuste. En particulier, la variable d'intérêt sera les précipitations journalières. Il concerne donc l'*Objectif n°1* de ce travail : l'intercomparaison et la caractérisation de la performance de méthodes de régionalisation du climat sur l'Europe de l'ouest, et plus précisément dans un contexte de climat présent (*Objectif n°1.1*).

Il est ici question de considérer de la façon la plus équitable possible des modèles se différenciant sur le plan conceptuel afin d'identifier les principales qualités et les défauts majeurs des modèles, de cibler les développements nécessaires et de fournir des sorties des SDMs comparables à celles des RCMs. Pour ce faire, nous adopterons le cadre de travail des simulations dit "hindcast" – i.e. utilisant les données d'un passé proche –, de l'initiative CORDEX [GIORGI et al., 2009]. Ceci impose certaines contraintes à cette étude afin que les simulations soient comparables notamment sur le domaine d'étude, la résolution spatiale et les données de forçage climatique du domaine d'étude. Ainsi notre étude ayant également pour but de contribuer à cette initiative, le cahier des charges suivant a été adopté :

- C1 les observations, les SDMs et les RCMs auront la même résolution spatiale (ici  $0.44^\circ$ ),
- C2 les variables grandes échelles (ou prédicteurs) seront choisies dans la base de données des Réanalyse ERA-interim [ERA-I, DEE et al., 2011] puisque c'est le forçage climatique adopté pour les simulations "hindcast" de CORDEX,
- C3 comme abordé au CHAPITRE I il existe plusieurs familles de modèles statistiques, nous nous attacherons donc à inclure au moins un représentant par famille ainsi qu'un nombre représentatif de modèles dynamiques.

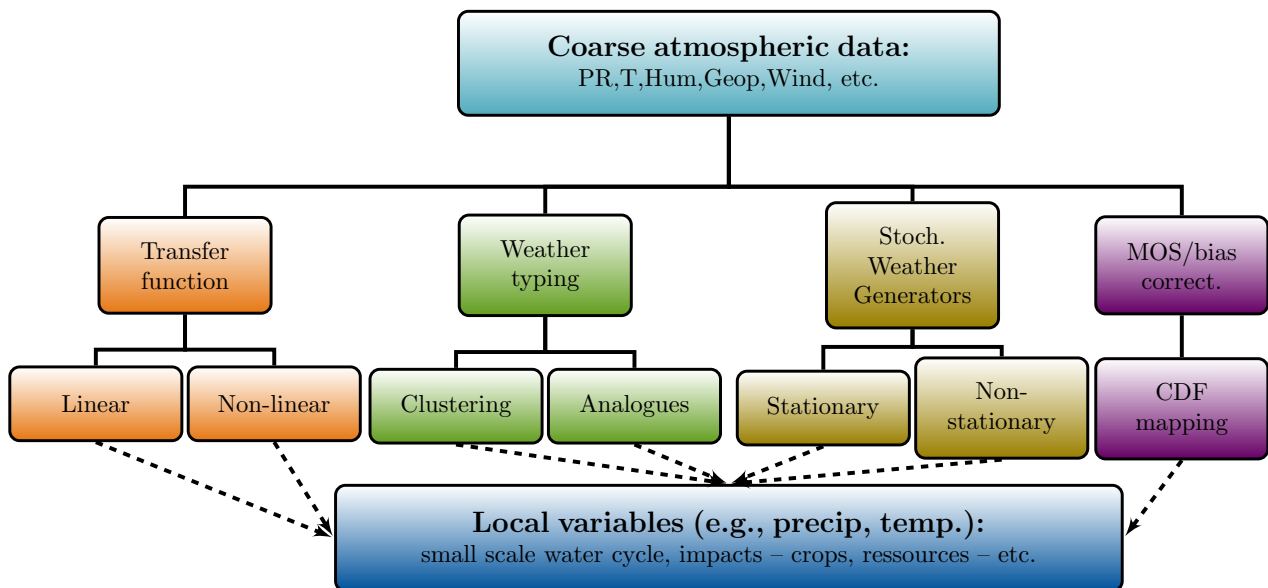


FIGURE II.1 – Schéma représentant les différentes familles de modèles statistiques [VRAC, 2012].

La FIGURE II.1 résume les différentes familles de SDMs. Plus de détails sur ces dernières sont disponibles au CHAPITRE I ainsi que dans l'introduction de l'article qui suit. Dans ce chapitre,

différentes déclinaisons des quatre approches vont être implémentées et évaluées aux côtés de modèles dynamiques. Nous précisons que nous ne cherchons pas ici à trouver le “meilleur” modèle mais à mettre au point une méthodologie permettant à un utilisateur de choisir le modèle qui répondra le mieux à ses besoins. L'évaluation des modèles sera conduite du point de vue climatologique à l'aide d'indicateurs pertinents. Et ceux-ci pourront être changés ou complétés si par exemple on considère un autre domaine d'application que la climatologie comme l'hydrologie par exemple et pourront mener à des résultats différents.

Pour résumer, l'intercomparaison suivante se situe dans le cadre des simulations “hindcast” de l'initiative CORDEX : tous les modèles devront être forcés par ERA-I sur la période 1989-2008 à une résolution de  $0.44^\circ$ , pour des sorties de précipitations. Ceci sera développé à la SECTION 2 sous forme d'une publication qui sera précédée d'un résumé en français. On complètera par des études portant sur le choix du seuil d'occurrence des précipitations à la SECTION 3 (cette question est abordée dans l'article).

Le choix des précipitations en tant que variable d'intérêt s'explique par sa haute variabilité spatiale et temporelle et les difficultés que pose sa modélisation par rapport à d'autres variables comme la température. On se situera sur les domaines EURO- et MED-CORDEX. Le choix de la période est une conséquence des simulations “hindcast” de CORDEX puisque qu'elles sont évaluées sur 1989-2008. Le choix de la résolution  $0.44^\circ$  (qui représente environ 50 km dans notre cas) est motivé par deux choses : la disponibilité des sorties de modèles dynamiques à cette résolution ainsi que celle d'un jeu d'observations grillées à la même résolution [ECA&D E-OBS V8 HAYLOCK et al., 2008 ], ce qui nous permet une comparaison directe entre les différents modèles et les observations.

## **2. Publication : Intercomparison of statistical and dynamical downscaling models under the EURO- and MED-CORDEX initiative framework : present climate evaluations**

### **Résumé étendu**

L'objectif de cet article est de comparer la capacité de différents modèles à reproduire les principales caractéristiques climatologiques des précipitations en se basant sur un jeu de données grillées de référence ici E-OBS. Ce résumé suit la progression de l'article en se focalisant sur quatre points : les données utilisées en tant que prédicteurs (ou variables de circulation à grande échelle) et prédictands (ou variables d'intérêt à l'échelle locale) ainsi que le cadre statistique décrit dans la section 2, les différents modèles utilisés dans l'étude et détaillés dans la section 3, les différents critères d'évaluation des modèles (voir section 4 de l'article) et les principaux résultats (section 5 de l'article). Le matériel supplémentaire de l'article est disponible dans l'ANNEXE A.

**N.B.** : la première section de l'article n'est pas résumée car elle concerne des points déjà évoqué en détails dans ce manuscrit (l'introduction de l'article correspond en partie à l'introduction de ce chapitre) notamment dans au CHAPITRE I, SECTION 3 de ce manuscrit. Un lecteur pressé pourra donc aller directement à la section 2 de l'article.

### *Données et cadre statistique<sup>1</sup>*

Comme nous l'avons vu, cette étude est largement conditionnée par les trois pré-requis prédemment énoncés. En particulier, cela affecte le choix des données : la résolution de  $0.44^\circ$  (C1) a été choisie pour éviter de transformer les sorties de modèles puisque nous disposons du jeu d'observations E-OBS (utilisé comme prédictand pour les SDMs et comme référence pour l'évaluation) et de sorties de RCMs à cette résolution ce qui répond à la première condition. Deuxième condition (C2), l'objectif étant également ici de s'inscrire dans l'exercice "hindcast" de CORDEX et en particulier sur les domaines EURO- et MED-CORDEX, les prédicteurs seront sélectionnés dans la base de données ERA-interim à  $1.125^\circ \times 1.125^\circ$  sur la zone géographique  $[-52.875^\circ\text{E} ; 76.50^\circ\text{E}] \times [20.25^\circ\text{N} ; 72.00^\circ\text{N}]$  englobant les deux domaines (cf. la figure 1 de l'article). Les variables physiques choisies sont : la température de rosée à 2m (D2), la température à 2m (T2), la pression au niveau de la mer (SLP), les composantes zonale et méridionale du vent et la hauteur du géopotential au niveau de pression de 850 hPa (U850, V850 and Z850). Les précipitations ont également été ajoutées en tant que prédicteurs communs à tous les SDMs. On prendra les deux premières composantes principales (PCs) obtenues après une analyse en composante principale (ACP) pour chacune des sept variables (pour plus de détails sur la procédure de sélection et de traitement se référer à la section 2.1 de l'article). La troisième contrainte principale (C3) est d'avoir un panel de modèles suffisamment représentatif des modèles aussi bien statistiques que dynamiques.

Afin de comparer des sorties de downscaling statistique robustes sur la période 1989-2008 nous allons utiliser une procédure dite de validation-croisée très commune en statistique. Cela consiste à calibrer (ou faire l'apprentissage) un modèle et l'évaluer sur des périodes de temps distinctes. Pour ce faire, nous fixons deux périodes de calibrations  $C_1=[1979-1998]$  and  $C_2=[1979-1988] \cup [1999-2008]$  et deux périodes de validations respectivement  $V_1=[1999-2008]$  and  $V_2=[1989-1998]$ . Ainsi, l'évaluation du modèle se fait sur  $V_2 \cup V_1=[1989-2008]$  (cf. figure 2 de l'article). Le seuil d'occurrence des précipitations est fixé à 1 mm.

### *Présentation des modèles comparés<sup>2</sup>*

#### SDMs

Parmi les quatre familles de SDMs (cf. FIGURE II.1), au moins un représentant a été implémenté pour chacune d'elle. La variable d'intérêt étant les précipitations, la modélisation de l'occurrence et de l'intensité sont usuellement réalisées séparément dans les modèles statistiques. C'est l'option que nous avons également choisi. Nous avons donc les modèles d'occurrence et les modèles d'intensité (qui eux sont choisis dans les quatre familles de SDMs) suivants :

- i. Occurrence ;
  - Seuiller à 1mm ;
  - Régression logistique (LR) ;

---

1. section 2 de l'article  
2. section 3 de l'article

ii. Intensité ;

- Fonctions de transfert : GAM, GAM-so [HASTIE & TIBSHIRANI, 1990] ;
- Types de temps : ANALOG [YIOU et al., 2013] ;
- Générateur de temps stochastique : SWG,SWG-s [CHANDLER & WHEATER, 2002] ;
- “MOS”/correction de biais : CDFt-so, [VRAC et al., 2012].

Les détails de chacun de ces six modèles statistiques sont disponibles à la section 3.1 de l'article.

RCMs

- MED-CORDEX [DROBINSKI et al., 2014] : Trois modèles, IPSL-WRF311, CNRM-ALADIN52, UCLM-PROMES ;
- EURO-CORDEX [VAUTARD et al., 2013] : Deux modèles, WRF-IPSL-INERIS44, ARPEGE-CNRM44.

Ces cinq modèles ont été très largement documentés, le tableau 3 de l'article synthétise les principales publications de référence.

*Procédure d'évaluation*<sup>1</sup>

L'évaluation de la capacité des 11 modèles à reproduire les principales caractéristiques du jeu d'observation se fait sur la période 1989-2008. Plusieurs indicateurs ont été implémentés sur cette période. Ils témoignent de la performance des modèles selon les quatre aspects suivants : l'occurrence, l'intensité et les propriétés spatiales et temporelles. La plupart d'entre eux sont calculés en tant que biais “Simulation-Observation”. Les indicateurs suivants ont été sélectionnés :

- Occurrence : le biais de la fréquence de jour de pluie, le biais de la persistance moyenne de jours de pluie et de jours secs et le Brier score ( $BS = \frac{1}{N} \sum_{t=1}^N (p_t - o_t)^2$ ,  $p_t$  la probabilité d'occurrence observée au temps  $t$ ,  $o_t$  l'occurrence observée (1=pluie, 0=non-pluie) et  $N$  le nombre de jours.) ;
- Intensité : le biais d'intensité moyenne, le ratio de variance, le biais du quantile 0.99 ;
- Propriétés Spatiales : analyse de la première EOF, la corrélation spatiale journalière ;
- Propriétés Temporelles : analyse de la variabilité interannuelle et du cycle saisonnier en terme de corrélation, ainsi que le coefficient d'autocorrélation à un jour.

*Principaux résultats*<sup>2</sup>

- Occurrence : en général, la modélisation de l'occurrence par une LR se révèle être une meilleure solution que le seuillage à 1 mm des sorties de modèles ;
- Intensité : ANALOG, CDFt-so, SWG and SWG-s ont les meilleurs scores. Les autres modèles ont de forts biais avec de fortes variations sur l'ensemble du domaine ;
- Propriétés Spatiales : ANALOG, CNRM RCMs et IPSL MEDCORDEX démontrent une meilleure habilité à reproduire la variabilité spatiale de E-OBS alors que les autres présentent des structures de variabilité différentes ou pas de structure du tout ;

---

1. section 4 de l'article  
2. section 5 de l'article

- Propriétés Temporelles : la variabilité interannuelle de E-OBS est mieux représentée par les RCMs alors que les SDMs s'en sortent mieux en ce qui concerne la saisonnalité. Pour ce qui est de l'autocorrélation à un jour, le modèle ANALOG suivi des RCMs la reproduisent correctement. Les autres SDMs manquent de qualité dans ce domaine.

Les principaux résultats montrent qu'aucun modèle n'est clairement supérieur aux autres. Les résultats dépendent quasi-entièrement des indicateurs choisis et *a fortiori* du domaine scientifique considéré et des besoins de l'utilisateur. Pour réaliser ce travail, un protocole aidant l'utilisateur à faire ce choix a été mis en place. Celui-ci aspire à être reproductible pour mener des travaux d'intercomparaison similaires et adaptables selon les besoins de l'utilisateur. Cette étude amène également un certain nombre de perspectives par exemple :

- l'application de ce protocole dans un contexte de climat futur ;
- l'élargissement du panel de modèles comparés ;
- l'ajout de nouveaux prédictors pour les SDMs ;
- l'utilisation d'une approche multi-modèle comprenant des simulations issues de RCMs et de SDMs faites dans le cadre de CORDEX ;
- le développement de nouveaux modèles etc.

Ces perspectives sont abordées dans l'article et nous reviendrons sur certaines d'entre elles à la SECTION 4 de ce chapitre.

# Intercomparison of statistical and dynamical downscaling models under the EURO- and MED-CORDEX initiative framework: present climate evaluations

Pradeebane Vaittinada Ayar<sup>1</sup> · Mathieu Vrac<sup>1</sup> · Sophie Bastin<sup>2,3,4</sup> · Julie Carreau<sup>5</sup> · Michel Déqué<sup>6</sup> · Clemente Gallardo<sup>7</sup>

Received: 9 October 2014 / Accepted: 7 May 2015  
© Springer-Verlag Berlin Heidelberg 2015

**Abstract** Given the coarse spatial resolution of General Circulation Models, finer scale projections of variables affected by local-scale processes such as precipitation are often needed to drive impacts models, for example in hydrology or ecology among other fields. This need for high-resolution data leads to apply projection techniques called downscaling. Downscaling can be performed according to two approaches: dynamical and statistical models. The latter approach is constituted by various statistical families conceptually different. If several studies have made some intercomparisons of existing downscaling models, none of them included all those families and approaches in a manner that all the models are equally considered. To this end, the present study conducts an intercomparison exercise under the EURO- and MED-CORDEX initiative hindcast

framework. Six Statistical Downscaling Models (SDMs) and five Regional Climate Models (RCMs) are compared in terms of precipitation outputs. The downscaled simulations are driven by the ERAinterim reanalyses over the 1989–2008 period over a common area at 0.44° of resolution. The 11 models are evaluated according to four aspects of the precipitation: occurrence, intensity, as well as spatial and temporal properties. For each aspect, one or several indicators are computed to discriminate the models. The results indicate that marginal properties of rain occurrence and intensity are better modelled by stochastic and resampling-based SDMs, while spatial and temporal variability are better modelled by RCMs and resampling-based SDM. These general conclusions have to be considered with caution because they rely on the chosen indicators and could change when considering other specific criteria. The indicators suit specific purpose and therefore the model evaluation results depend on the end-users point of view and how they intend to use with model outputs. Nevertheless, building on previous intercomparison exercises, this study provides a consistent intercomparison framework, including both SDMs and RCMs, which is designed to be flexible, i.e., other models and indicators can easily be added. More generally, this framework provides a tool to select the downscaling model to be used according to the statistical properties of the local-scale climate data to drive properly specific impact models.

**Electronic supplementary material** The online version of this article (doi:10.1007/s00382-015-2647-5) contains supplementary material, which is available to authorized users.

✉ Pradeebane Vaittinada Ayar  
pvait@lsce.ipsl.fr

- <sup>1</sup> Laboratoire des Sciences du Climat et de l'Environnement (LSCE-IPSL), CNRS/CEA/UVSQ, Centre d'Etudes de Saclay, Orme des Merisiers, 91191 Gif-sur-Yvette, France
- <sup>2</sup> Université Versailles St-Quentin, Versailles, France
- <sup>3</sup> Sorbonne Universités, UPMC Univ. Paris 06, Paris, France
- <sup>4</sup> CNRS/INSU, LATMOS-IPSL, 11 bd d'Alembert, 78280 Guyancourt, France
- <sup>5</sup> HydroSciences Montpellier (HSM), CNRS/IRD/UM1/UM2, Place Eugène Bataillon, 34095 Montpellier, France
- <sup>6</sup> Météo-France, Centre National de Recherches Météorologiques, 42 Av. Coriolis, 31057 Toulouse, France
- <sup>7</sup> Instituto de Ciencias Ambientales, Universidad de Castilla-La Mancha, Toledo, Spain

**Keywords** Statistical downscaling · Dynamical downscaling · CORDEX · Precipitation · Intercomparison

## 1 Introduction

The study of the many environmental and socio-economic impacts of meteorological phenomena and climate change

implies to improve our knowledge of climate at a local scale. Indeed, studying climate change impacts on agriculture, water resources, pollution, and many other environmental features at a human scale makes high-resolution model simulations essential. However, General Circulation Model (GCM) simulations of the different future climate scenarios prescribed by the Intergovernmental Panel on Climate Change [Vuuren et al., 2011] have generally a coarse spatial resolution (about 250 km) and are thus not adapted as inputs into the impacts models that need much finer scale climate information. Hence, it is required to bring GCMs climate simulations information to more regional or local scales, i.e., to generate high-resolution simulations based on (reanalyses or GCM) large-scale information. This is the aim of downscaling. Downscaling models can be dynamical or statistical, both approaches being driven by GCMs or reanalysis data.

Dynamical downscaling models correspond to the so called “Regional Climate Models” (RCM), which simulate high-resolution physical processes consistent with the prescribed large-scale dynamics. RCMs can be a GCM with grid refinement over a specific region [e.g., Déqué & Pielke, 1995; Hourdin et al., 2006] or a limited area model (LAM) constrained at its lateral boundaries by GCMs [WRF, Skamarock et al., 2008]. Both GCMs and LAMs are sensitive to the resolution and the physical package which regroups all the model parametrization used in the model to take into account sub-grid scale processes. While the use of LAMs presents some advantages, for instance the fact that they are non-hydrostatic allows very high-resolution downscaling or also the possibility to set a region-specific parametrization, it also creates discontinuities at the boundaries. Previous studies have investigated the sensitivity of the results to the frequency of boundary conditions, size and resolution of the domain [e.g., Noguer et al., 1998; Seth & Giorgi, 1998], lateral conditions [Denis et al., 2003] and frequency of reinitialization [Lo et al., 2008]. Those studies show that the internal variability of RCMs can strongly influence the results at regional scales and that the smallscale field inside the domain is not always consistent with the driving field [Laprise

et al., 2008]. To ensure the consistency between the small- and large-scale fields, the model can be driven using nudging techniques [e.g., Omrani et al., 2012a; Omrani et al., 2012b]. The choice of the physical package that allows the model to simulate all the sub-grid scale processes using parameterizations is also very important and induces large discrepancies between model outputs [e.g., Flaounas et al., 2011]. Despite the increase of computing power, running an RCM including all those different formulations still requires important computational resources. This often puts limits on the number, the resolution and the time period length of the RCMs runs.

The alternative approach to RCMs is based on Statistical Downscaling Models (SDMs) that rely on determining statistical relationships between large- and local-scale variables and do not try to solve the physical equations modelling the dynamic of the atmosphere. Due to their statistical formulation, they generally have a low computational cost and provide relatively fast simulations. SDMs are now considered as complementary to RCMs, for example in terms of applications for ensembles uncertainties studies [Sachindra et al., 2014]. SDMs are based on a static relationship, *i.e.* the mathematical formulation of the relation between predictand (*i.e.*, the local-scale variable to simulate) and predictors (*i.e.*, the large-scale information or data used as inputs in the SDMs) is supposed to be valid for any time period: not only for the current climate on which the relationship is calibrated, but also, for example, for future climates. This does not mean that the statistical properties of the predictands are stationary (*i.e.*, are the same in current and future climates): if the statistical properties of the large-scale predictors evolve in time, those of the local scale predictands will evolve as well. Hence, if the relationship is said to be “static” (or “stationary”), the statistical distribution of the predictands is “non-stationary” and the SDMs can be said to be non-homogeneous [e.g., Vrac et al., 2007d]. Most state-of-the-art SDMs can be divided into the four following families: transfer functions (TFs), stochastic weather generators (WGs), weather typing (WT) based methods and model output statistics (MOS).

The TFs approach regroups the deterministic functions which “transfer” the large-scale information to the local scale. Those mathematical functions characterize the nature of the dependencies between the predictors and the predictands. They could be linear [e.g. through a multi-linear regression (MLR), see Jeong et al., 2012 ] or non-linear [e.g. through polynomial regression or artificial neural network (ANN), see Xiaoli et al., 2008 ]. These methods are usually easy to implement and apply but tend to underestimate the variance [see the variance inflation procedure in Wilby et al., 2002 ]. One solution is to use a stochastic modelling in order to adapt the statistical distribution instead of “inflating” the variance.

Stochastic WGs simulate daily weather scenarios thanks to probability distribution functions (pdfs) estimated from observations. A wide range of WGs has been developed to generate weather variables [e.g., see for a review Wilks, 2012 ]. Historically, WGs were used to reproduce the observed rain statistical properties [Wilks, 2010]. However, in a downscaling context where the statistical properties may evolve in time, WGs have to be based on pdfs that depend on atmospheric predictors. These conditional pdfs can evolve in time, i.e., their parameters can change with the predictors [e.g. Bardossy & Plate, 1992 ]. This approach is particularly interesting to generate variability in data.

The WT approach defines large-scale patterns from circulation variables and rely on clustering techniques. The main assumption is that for a given large-scale pattern, the relationship between the large- and local-scale variables is always the same. One particular method is the “analog” method where each daily large-scale situation is considered as a pattern. For a day to be down-scaled, the day in the past which has the closest large-scale situation (according to a similarity metric) is chosen (Zorita and Storch 1999). The local-scale observations of the selected day are then the downscaled values. This approach also provides methods easy to implement. However, in climate change context these methods can miss a possible

climate change signal because of their inability to generate values beyond the range of past values.

All the previous approaches need daily synchronicity between large-scale and local-scale data to be calibrated. They are referred to as “Perfect-prog” downscaling [Klein et al., 1959]. Model output statistics approach is quite different by essence because it generally works directly on model outputs, without calibration based on reanalysis data. MOS aims to link characteristics like the mean, the variance or the probability (or cumulative) distribution function (pdf or CDF). This approach presents many interesting applications in terms of downscaling and bias correction but the performance is deeply linked to the quality of the modelled large-scale variable [Coiffier, 2011].

Many different intercomparison studies have been conducted lately. These studies have a wide range of purposes. They can be discriminated for instance by the type of models which were compared: RCMs only, SDMs only or both SDMs and RCMs.

Concerning RCMs, several coordinated projects have been developed involving collaborations between Regional Climate Modelling groups. There are several projects taking place around the world over different regions. Over Europe, the MERCURE project [1997–2000, Machenhauer et al., 1998 ], aimed at identifying the strengths and weaknesses of RCM simulations driven by atmospheric analyses. It led to the project PRUDENCE<sup>1</sup>, [2001–2004, Christensen & Christensen, 2007 ] where one important goal was to analyse future projections according to four uncertainty aspects: natural variability, greenhouse gases emissions and concentrations scenarios, the choice of the driving GCM atmospheric and oceanic boundary conditions and finally the RCM formulation. This was followed by the project ENSEMBLES<sup>2</sup> [2004–2009, Hewitt, 2004 ]. It produced for the first time a probabilistic estimate of uncertainty of future climate at several timescales, using an ensemble validated against observational datasets for Europe. Note that similar projects exist over other regions like the Asian RMIP project [Fu et al., 2005] or the North American projects PIRCS

---

1. <http://prudence.dmi.dk/>

2. <http://www.ensembles-eu.org>.



[Takle et al., 1999] and NARCCAP [Mearns et al., 2013]. Lately, the Coordinated Regional Climate Downscaling Experiment [CORDEX, Giorgi et al., 2009] initiative from the World Climate Research Program promotes running multiple RCM simulations at 50 km and higher resolution for multiple regions. This initiative is mainly aiming to assess RCMs quality and uncertainty for the recent past and for twenty first century projections, covering the majority of populated land regions on the globe. The uncertainties are associated with varying GCMs simulations, varying greenhouse gas concentration scenarios, natural climate variability and different downscaling methods. In contrast to the former intercomparisons, the CORDEX initiative impose several additional and mandatory constraints which make the runs comparable. The constraints include domains definition, time period, same spatial resolution and boundary forcing [ERAinterim Reanalysis, Dee et al., 2011] for the hindcast evaluation to provide a framework for model evaluation and assessment.

SDMs-focused intercomparisons are also more and more available now but are mostly done by modest research initiatives compared to CORDEX for instance. One of the first intercomparison studies was brought by Wilby & Wigley [1997], who aimed to make a review of the available SDMs at the time and to compare precipitation models in terms of present and future climate over north America. Six SDMs calibrated on NCEP reanalyses have been compared with one GCM. The main result pointed out intervariable inconsistencies in the GCM which made unreliable the precipitation changes generated by the GCM. Even if this study was quite exhaustive, the MOS approach was not represented in it.

Since then, many intercomparison studies have been conducted, often not taking into account one or several SDM approaches and with specific purposes. For instance, Schoof & Pryor [2001] aimed to compare two TF methods calibrated over circulation indices on midwestern USA. The evaluation performed on present climate pointed out that the models failed to capture the variability of precipitation as governed by the large-scale circulation and suggested that other variables were necessary to capture precipitation. Although this paper is

an important contribution, only TF methods were discussed in this study. Focussing also mostly on TFs methods, Harpham & Wilby [2005] evaluated two ANN-based SDMs (i.e., TF) and one WG to downscale heavy precipitation and their multi-site behaviour in a present climate context over United Kingdoms. A follow up study included three supplementary SDMs and two RCMs in a future climate context [Haylock et al., 2006]. The results underlined the need of an ensemble approach when considering future climate projections. However, the WT approach was missing in the first study and the MOS approach in both studies. Similar studies conducted over the Serpent River basin (Quebec, Canada) aimed to focus on a particular temporal neural network (TNN, i.e., TF) to downscale precipitation [Dibike & Coulibaly, 2006; Khan et al., 2006]. Results showed the high-performance of that particular TNN model but the study did not include WT and MOS models in both cases. Moreover, in a recent study, Gaitan et al. [2014] aimed to compare high-resolution precipitation models over Ontario and Quebec, Canada to reproduce climate change signal based on the RCM pseudo-observation approach developed in Vrac et al. [2007a]. Six rain occurrence WT models and four rain intensity TF models have been designed to this end from the same set of predictors. Their ANN (i.e., TF named ANN-F in their study) was found to be the best model. Although an interesting intercomparison, the study did not investigate MOS and WG approaches.

Other recent studies compared methods from the four statistical families but with different predictors. For instance, six SDMs and three RCMs precipitation outputs were compared over the Alps by Schmidli et al. [2007]. The SDMs were calibrated on several reanalysis databases for present climate and applied to GCMs for future climate. Results showed that the statistics of most statistically and dynamically downscaled precipitation were similar. In another study by Bürger et al. [2012b], five SDMs with their own set of predictors have been evaluated in a present climate context over British Columbia, Canada, focusing on extremes aspects of the compared SDMs for temperature and precipitation. It turned out that the use of hybrid models (i.e., models with compo-

nents built from several families) made difficult to identify the component of the models which explains the model efficiency. Even if all the SDMs families were studied in both papers, the models were calibrated on different sets of predictors. A common set of predictors would have allowed an easier comparison.

All these references are examples and this list is by no means exhaustive. They give a general idea of some major studies. More generally, all those studies did not include a cross-validation procedure in their model evaluation [except in Gaitan et al., 2014 and also in Vrac et al., 2007a] which is an important step to validate SDMs in a present climate context (this notion is illustrated in SECTION 2.2. Even if they compared many models with different interesting features and results, they all presented some inconsistencies. Indeed, one important argument is that in most studies the predictors were different: for instance they were selected according to the observation station [Harpham & Wilby, 2005; Haylock et al., 2006; Dibike & Coulibaly, 2006; Khan et al., 2006] or were specific to the models features [Schmidli et al., 2007; Bürger et al., 2012b]. Sometimes the purpose of the study was not the intercomparison itself but rather to underline the developments of a new model [e.g., Dibike & Coulibaly, 2006; Harpham & Wilby, 2005 ]. As said above, in most of the studies at least one type of model is missing and the SDMs were calibrated on more or less sparse observation network. In this paper, to perform a consistent intercomparison, we want to compare models outputs from all types of models [i.e., from the four approaches of SDMs and from RCMs, see Schmidli et al., 2007 ] and observational data with similar resolution over a common area. Another criterion is to calibrate all the models with a common set of predictors (as much as possible) with a cross-validation procedure [see Gaitan et al., 2014 ]. Thus, the three main requirements of this intercomparison study are: (1) models must have common predictors, (2) RCMs and SDMs model outputs and observations have to share the same area and resolution, (3) all SDMs families models have to be represented and a representative number of dynamical models have to be included. Recently, two initiatives sharing similar

objectives have to be mentioned: CORDEX-ESD (<http://wcrp-cordex.ipsl.jussieu.fr/index.php/community/cordex-esd>), and the COST Action VALUE [<http://www.value-cost.eu/>, Maraun et al., 2015 ]. These projects aim at coordinating SDMs intercomparison at a continental scale and make SDMs comparable to RCMs.

The present intercomparison takes place under the CORDEX initiative hindcast evaluation: all the models have to be forced by ERAinterm reanalyses and run over the 1989–2008 period at  $0.44^\circ$  resolution. For the present study, the variable of interest is the precipitation. This choice is motivated by its high spatial and temporal variability and the difficulties faced to model precipitation compared to other variables like temperature. Another argument is that rainfall is one of the most important variables for many impact studies [e.g. for floods prediction, Raje & Mujumdar, 2010 or crop yields, Oettli et al., 2011].

Hence, in this paper, several downscaling models are compared through a common and well defined framework. The aim is to set a generic intercomparison framework. More precisely, our goal is not to select the best model or to develop a model with new features. The objective is to design an intercomparison experiment in which the models are easily confrontable. The performance criteria are expected to be wide enough to correctly inspect the main aspects of the models representing each statistical downscaling family. The chosen indicators are relevant for climatological studies. Indeed, these can be different when considering other application domains (e.g. hydrology), which can produces different performance evaluation results. The proposed framework would help to point out main models strengths and weaknesses, identify the needed improvements and provide statistically simulated time series to be compared to RCMs over a common area and forced by a common set of predictors (ERAinterim). Differences between models with specific features both in conceptual terms, e.g., dynamical versus statistical or deterministic versus stochastic, and technical details are going to be described and evaluated. This intercomparison is also designed in a way that other models or indicators can be easily added.

This paper is organized as follows: the data and experimental set-up are presented in SECTION 2, while SECTION 3 describes the downscaling models

used in this study. The results of the comparison are presented in SECTION 4. Finally, in SECTION 5, some conclusions, perspectives and discussions are proposed.

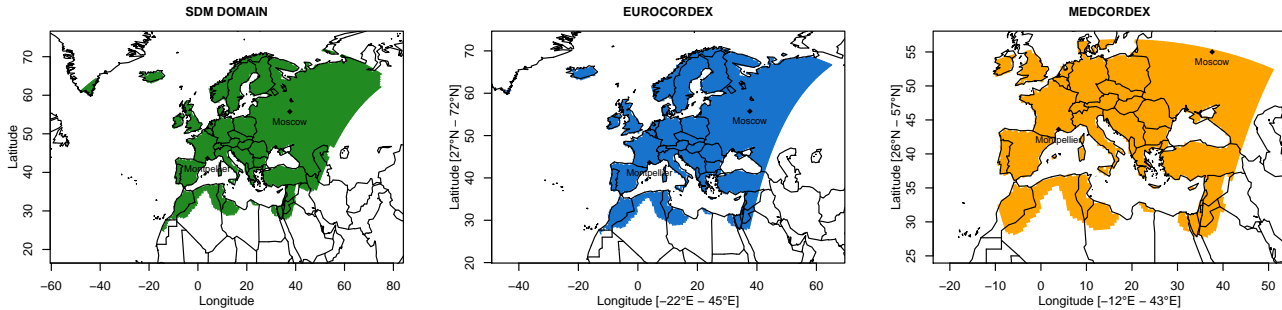


Figure 1: The models are run and evaluated over the following geographical areas: the SDMs domain in *green* corresponding to the E-OBS domain, the intersection between EURO-CORDEX and E-OBS domain in *blue* which is the evaluation domain of EURO-CORDEX models and the intersection between MED-CORDEX and E-OBS domain in *orange* which is the evaluation domain of MED-CORDEX models.

## 2. Data and experimental setup

SDMs seek to establish a link between large-scale and local-scale climate data. The experimental setup thus has to state which large-scale variables will act as predictors and which local-scale variables will be predicted. In addition, the validation procedure has to be defined. In order to design the experiment rigorously, it is essential to keep in mind assumptions under which the SDMs are performed [Hewitson & Crane, 1996]: (1) the relationship between local-scale data and large-scale predictors is fixed in time (even if the statistical properties of the downscaled simulations can evolve in time), (2) the predictors fully represent the climate signal, (3) the large-scale variables are well reproduced by climate models, including reanalysis.

### 2.1. Local-scale predictands and large-scale predictors

In order to limit any RCM data transformation from their initial spatial resolution, the common resolution of the RCMs at  $0.44^\circ$  or local-scale predictands has been chosen. Therefore, the comparison with the E-OBS V8 gridded dataset from the EU-FP6 project ENSEMBLES<sup>1</sup> and the data providers in the ECA&D project is straightforward<sup>2</sup> [Haylock et al., 2008] at  $0.44^\circ \times 0.44^\circ$ . In

the experimental setup, the E-OBS precipitation data will serve as localscale reference predictand for the calibration of the statistical models that will therefore downscale large-scale information to  $0.44^\circ$  spatial resolution, directly comparable to RCMs outputs. Note that there are some quality inconsistencies in this version of E-OBS data [Hofstra et al., 2009]. The reader has to keep in mind that this intercomparaison is done using E-OBS data as reference, which can potentially induce some inexact results over specific areas. This issue is discussed in SECTION 5.2.

As one of the goal of this study is to make inter-comparisons between SDMs and RCMs involved in the EURO-CORDEX [Jacob et al., 2014] and MED-CORDEX/HYMEX [Drobinski et al., 2014 [www.medcordex.eu/medcordex.php](http://www.medcordex.eu/medcordex.php)] initiatives, the atmospheric data chosen to drive the statistical models (i.e., the large-scale predictors) are the same as those used as forcing for the RCMs for the hindcast evaluation. FIGURE 1 represents the geographical areas over which the models are evaluated: in green the SDMs domain corresponding to the domain of E-OBS data, in blue the EURO-CORDEX evaluation domain which is the intersection between EURO-CORDEX and E-OBS domain and in orange the MED-CORDEX evaluation domain which is the intersection between

1. <http://ensembles-eu.metoffice.com>.

2. <http://www.ecad.eu>.

MEDCORDEX and E-OBS domain. The atmospheric variables used as predictors are selected from the ERA-interim Reanalysis [ERAi, Dee et al., 2011] at  $1.125^\circ \times 1.125^\circ$  resolution, over the North-Atlantic region which includes the EURO-CORDEX and MED-CORDEX domains. It corresponds to 5,452 grid-points over the geographical area  $[-52.875^\circ\text{E} ; 76.50^\circ\text{E}] \times [20.25^\circ\text{N} ; 72.00^\circ\text{N}]$ .

All fields are taken at the daily time scale obtained by averaging 6 h reanalyses outputs. These variables are selected according to many criteria. First, considering the objective of our study which is to intercompare models, a common set of predictors for all the statistical models is needed. Such a consideration makes the study as fair as possible in the way the models are considered. The choice

Predictors	D2	SLP	T2	R850	U850	V850	Z850	PR
<b>Winter</b>	0.635 (2)	0.679 (1)	0.572 (3)	-	0.298 (5)	0.355 (4)	-	Common predictor
<b>Summer</b>	0.508 (2)	0.342 (5)	0.515 (1)	-	0.444 (3)	-	0.403 (4)	Common predictor

Table 1: Selected predictors for each season and their correlation and rank into parenthesis given by SPARSE CCA algorithm. These variables are: the dew point at 2m (D2), the temperature at 2m (T2), the sea level pressure (SLP), the relative humidity, the zonal and meridional wind components and the geopotential height at 850 hPa pressure level (R850, U850, V850 and Z850). Besides the large-scale precipitation (PR) is added as common predictor.

is also motivated by the physical relation of the variables to the precipitation and their role in the precipitation processes. Another criterion is the availability of the common variables in GCMs and Reanalysis products and also the correct representation of the predictors over the domain [Hewitson & Crane, 1996]. Note that this is not a requirement for the intercomparison itself (one can imagine an intercomparison with badly simulated predictors) but only for our choice of predictors. TABLE 1 shows the chosen variables. Some of them have been widely used in statistical downscaling context with good results. For instance, surface variables such as the temperature at 2 m (T2), the sea level pressure (SLP) or atmospheric variable as the geopotential height, the zonal and meridional wind components and relative humidity at 850 hPa (Z850, U850, V850, R850) can be found in studies like Cavazos & Hewitson [2005] or Crawford et al. [2007]. The dew point at 2 m (D2) was also added. Physically, precipitation results from saturation of water vapour due to a vertical lift of the atmospheric cell, that is to say a combination between atmospheric instability and humidity convergence. As saturation is a non-linear function of temperature and moisture, it is important to include both temperature and moisture (relative, specific, or dew point temperature) as predictors. Moreover, SLP (or geopotential height at some tropospheric level) is a good largescale predictor

candidate, as it includes the direction of the advection (which implicitly interacts with orography) and the convergent motions (which produce also vertical lift). The U and V components of the wind bring also relevant information in terms of synoptic motions. Finally, using two levels (SLP and Z850) enables to take into account, to some extent, the vertical stability of the lower troposphere through the baroclinicity. T2 also accounts for the degree of atmospheric stability. A statistical analysis based on sparse canonical correlation analysis [SPARSE CCA, Witten et al., 2009] was conducted and corroborates our choice of predictors. Traditional CCA seeks the best projections of two sets of variables (in our case, the predictors and the predictand over the spatial domain) by iteratively maximizing the correlation of the projections. The sparse version of CCA adds sparsity constraints on the projections resulting in projection vectors with a number of zero coefficients which depends on the sparsity enforced. Each potential predictor variable was first spatially summarized by taking its first principal component (PC) computed from a principal component analysis [PCA, Barnston & Livezey, 1987] applied—separately for each climate variable—to the 5,452 grid-points over the North-Atlantic region. Then SPARSE CCA was carried out between a set containing the first PC of each of the seven potential predictors and a second set of variables comprising the precipitation

on the EURO-CORDEX area. Only the first PC is considered to summarize spatially a climate variable. Two points motivated this choice. First, the physical/atmospheric variables that make sense as predictors for precipitation downscaling only at the first order have been determined. Hence, a natural choice was to retain only the first PC. Second, applying the SPARSE CCA algorithm over the whole EUROCORDEX region based on the relatively high-resolution E-OBS dataset is computationally intensive, even for a single principal component. Therefore it has been decided to limit this first exploratory step of SPARSE CCA to only the first PC. The sparsity constraints are tuned so that only one predictor variable appears in each projection vectors (only one non-zero coefficient). Thus, each predictor variable is associated with a rank given by the correlation (see TABLE 1) with the projected predictand. The representation of some predictors have known issues in some GCMs, in particular R850 and D2 included in this study. The humidity has proven itself to improve the quality of the downscaled precipitation estimates [e.g., Vrac et al., 2007d]. Therefore, although some GCMs may have some problems to represent this variable, it was decided to include it among the variables to be tested in the CCA analysis. The outcome of the SPARSE CCA excludes the relative humidity as a predictor. Instead, the dew point temperature at 2 m (D2), an index of moisture saturation [Charles et al., 1999], is kept. Although D2 depends on humidity, it also integrates pressure and temperature in its computation, two physical variables that are expected to be relatively well represented by most GCMs. The dew point temperature is then expected to be relatively well represented. The MOS model uses only the large-scale variable as predictor (*cf.* SECTION 3.1.5). As precipitation is usually not well represented by the GCMs, this variable is rarely employed as a predictor in Statistical Downscaling Models. Nevertheless, in the present intercomparison exercise since it is aimed at having predictors as common as possible, the large-scale precipitation has also been added in order to have at least one common predictor for all the SDMs. More precisely, to account for the non-Gaussian behaviour of the daily precipitation whose distribution is generally skewed, a

transformation of the precipitation data has to be performed before applying PCA. Hence, as in Vrac & Friederichs [2015], the zero precipitation values have been set to a small value different from zero (0.00033) and the logarithm of all precipitation data (with 0's transformed to 0.00033) have been computed.

The SPARSE CCA was carried out over two 6-month periods: a 6-month “summer” (from April, 15th, to October, 14th) and 6-month “winter” (from October, 15th, to April, 14th). TABLE 1 shows the selected predictors for each season and their order according to the rank given by SPARSE CCA: the first five variables have been selected for each season. For the intercomparison, the first two PCs of each selected large-scale variable are kept as predictors. This choice is made to avoid the optimization of too many parameters since the SDMs calibrations/simulations are pointwise over 6043 E-OBS grid-points. This is a tradeoff to keep a relatively low complexity (*i.e.*, a relatively low number of parameters)—especially for the stochastic and TFs models—while including a significant number of physical variables as predictors. The variable selection preprocessing resulted in 12 predictors (2 first PCs for each of the 5 variables selected through the SPARSE CCA and precipitation). For example, this corresponds for the stochastic models, to 39 parameters to be estimated (13 for the occurrences, 26 for the intensity, see SECTION 3.1.3) for each of the 6043 E-OBS grid-points.

## 2.2. Cross-validation set up

In order to intercompare some SDMs and RCMs involved in the CORDEX exercise, all evaluations have to be made within the constraints of this program, *i.e.*, over the 1989–2008 time period which is the hindcast evaluation time period. FIGURE 2 sketches the two calibrations ( $C_1$  and  $C_2$ ) and validations ( $V_1$  and  $V_2$ ) time periods used in this study for SDMs. The models are trained and validated sequentially, first over  $C_1$  (*i.e.*, [1979–1998]) and  $V_1$  (*i.e.*, [1999–2008]) respectively and then over  $C_2$  (*i.e.*, [1979–1988]  $\cup$  [1999–2008]) and  $V_2$  (*i.e.*, [1989–1998]) respectively. The model evaluation is performed over  $V_2 \cup V_1 = 1989$  to 2008, therefore with the outputs of two different calibrations per model. The rain occurrence threshold



Figure 2: Cross-validation scheme over the period 1979-2008 with two calibrations ( $C_1=[1979-1998]$  and  $C_2=[1979-1988] \cup [1999-2008]$ ) and two validations ( $V_1=[1999-2008]$  and  $V_2=[1989-1998]$ ) periods. The Intercomparison is done over the period  $V_2 \cup V_1=[1989-2008]$  corresponding to the CORDEX RCM runs period.

is set at 1 mm per day for the evaluation. In the literature, a wide panel of thresholds has been used: 0 mm in Semenov et al. [1998], 0.5 mm in Ambrosino et al. [2014] or 5mm in Bouvier et al. [2003]. In this study, a middle ground is stroke and a threshold of 1 mm is selected since it is commonly used [e.g., Schmidli et al., 2007 ].

### 3. Statistical and dynamical downscaling models

#### 3.1. Statistical downscaling models

One SDM per each of the four families of approaches (TF, WG, WT-based methods and MOS) has been selected potentially with some variants—in order to evaluate the main philosophical and technical features between the different approaches, e.g., deterministic versus stochastic. Statistical modelling of precipitation is usually divided in two successive steps: first the occurrence and then the intensity. Section 3.1.1 describes rain occurrence modelling and Sects. 3.1.2 to 3.1.5 the different rain intensity models.

##### 3.1.1. Rain occurrence

In this study, two ways to model rain occurrence are considered. In the first way, the model outputs are simply thresholded at a given level (1 mm in that case) from a model including zeros and making no difference between 0's and positive values. If negative values are generated, they are set to 0. In the other way, rain occurrence at a given location is modelled as a binomial distribution  $B(1, p)$  using a logistic regression [LR, see Buisson et al., 2004; Fealy & Sweeney, 2007 ]. Let  $p_i$  be the probability of rain for the day  $i$  conditionally to a  $N$ -length predictor (or covariate) vector  $\mathbf{X}_i$ . The conditional probability of occurrence  $p_i$

is formulated through an LR as:

$$\log\left(\frac{p_i}{1-p_i}\right) = \underbrace{P^0 + \sum_{j=1}^N P^j X_{i,j}}_{=S} \quad (1)$$

$$\Leftrightarrow p_i = \frac{\exp(S)}{1+\exp(S)}, \quad (2)$$

where  $(P^0, P^1, \dots, P^N)$  is a vector of coefficients to be estimated. Based on the predictors for day  $i$ , EQUATION (1 and 2) provides the probability of rain from which it is easy to simulate a rainfall occurrence. Computational details to estimate  $p_i$  are available in “Appendix”.

##### 3.1.2. Transfer functions (TFs)

The models belonging to this family link directly the large-scale information to local-scale variables using deterministic functions. As stated in the introduction, those functions characterize the nature (linear or non-linear) of the predictors-predictand relationships. For this approach the Generalized Additive Models (GAM) framework [Hastie & Tibshirani, 1990] has been chosen. It is a deterministic model which consists in modelling the expectation of  $Y$  (here, the precipitation) conditionally on the  $N$  large-scale predictors  $(X_1 \dots X_N)$  as a sum of spline functions  $f_j(X_j)$ :

$$E(Y|X_1 \dots X_N) = \sum_{j=1}^N f_j(X_j) \quad (3)$$

where  $f_j$  are cubic regression spline functions. The cubic splines have a relatively low complexity while allowing a high non-linearity to model the link between  $X_j$  and  $Y$ , *i.e.*, the large- and the local-scale data. This method has been applied for the present time period, for instance to downscale the near surface wind fields in Salameh et al. [2009], or for

the Last Glacial Maximum time period (-21 ky), to retrieve monthly climatology for temperature and precipitation over Europe [Vrac et al., 2007c] or global permafrost [Levassasseur et al., 2011]. GAM is a data-driven approach in the sense that it allows to model both piecewise linearities and non-linearities depending on the nature of the predictor-predictand dependence. Two variants have been defined in the present study: (1) GAM and (2) GAM-so. In the first one, GAM has been calibrated with all values (*i.e.*, including 0's) and then rain intensity has been directly simulated and the rain occurrence is dealt by thresholding the outputs at 1 mm. In the second one (*i.e.*, the GAM-so approach), the LR is first used to model the occurrence and then  $E(\log(Y)|X_1 \dots X_N)$  (instead of  $E(Y|X_1 \dots X_N)$ ) has been modelled for positive rain intensities. Computational details for GAM simulations are available in "Appendix".

### 3.1.3. Stochastic weather generator (WG)

WGs are models generating daily weather scenario thanks to pdfs estimated from observations. As previously stated they are mainly used to simulate data whose statistical properties are similar to those of observations. They present a large diversity in terms of techniques and complexity: starting from quite simple series generators [e.g., Semenov & Stratonovitch, 2010], passing through Markov chain based models [e.g., Kilsby et al., 2007] to sophisticated approaches like the observed hierarchical organization of rainfall and rain-cell space and time-clustering processes [e.g., Onof et al., 2000]. One way to build a stochastic SDM is based on generalized linear models (GLMs). GLMs have been first applied by Stern & Coe [1984] for the generation of precipitation. GLMs link the expected mean of a random variable to the  $N$  predictors as:

$$g(\mu) = \sum_{j=1}^N \theta^j \cdot X_j \quad (4)$$

where  $\mu$  is the expected mean,  $\theta_j$  are regression coefficients to be estimated and  $g(\cdot)$  a monotonic link function. In this work, an extension of this formulation is used. Conditional pdfs are used to model the precipitation in a Vectorised Generalized Linear Models (VGLM) framework as in

Chandler & Wheeler [2002]. It means that the distribution family is fixed and the distribution parameters are estimated by a GLM. Thus, the rain distribution parameters for each day are estimated from the selected predictors. This method allows also the simulation of spatio-temporal rainfall with an appropriate covariance function [Yang et al., 2005] or at subdaily temporal resolution [Mezghani & Hingray, 2009]. In all those works a two-step approach is implemented to model precipitation. It stands as follows:

- i. Rain occurrence is modelled by an LR as given in EQUATIONS (1 and 2),
- ii. Rain intensity is supposed to follow a Gamma distribution  $\Gamma_{\alpha,\beta}(\cdot)$  whose parameters shape  $\alpha$  and rate  $\beta$  are functions of the large-scale predictors at day  $i$ :

$$\begin{cases} \log(\alpha_i) &= \alpha^0 + \sum_{j=1}^N \alpha^j X_{i,j} \\ \log(\beta_i) &= \beta^0 + \sum_{j=1}^N \beta^j X_{i,j} \end{cases} \quad (5)$$

Hence, for each day the parameters are calculated and a distribution is retrieved, which makes the model non-stationary and able to evolve with predictors. Then, simulations are performed based on the daily pdf. Note that the Gamma distribution parameters have been estimated from all values above 0 mm but only rain amounts above 1 mm are simulated. Indeed, estimating the Gamma distribution for values above 1 mm makes the hypothesis of a Gamma to simulate rain intensity no longer valid. Besides, calibrating the model over precipitation amounts above 1 mm causes an artificial increase of the variability of the generated time series: the variance is about twice the variance of the data generated from a calibration with all positive precipitation (not shown). Computational details to infer the Gamma distribution parameters are available in "Appendix".

In the following, two variants are applied and tested: (1) SWG, the non-stationary model described above in EQUATIONS (1 and 5), and (2) SWG-s, the stationary version of SWG, where the occurrence probability and the parameters  $\alpha$  and  $\beta$  are constant and do not depend on any predictor. All the parameters of both variants are estimated



by maximizing the likelihood function, except the constant occurrence probability (hereafter referred to as COP), which corresponds to the observed occurrence.

#### 3.1.4. Weather typing (WT)

The WT family is based on large-scale circulation (LSC) patterns. It relies on the idea that the same LSC situation (i.e., predictors) produces the same local-scale effects (here E-OBS rain fields). WT consists in regrouping days with similar LSCs. This is classically done with statistical clustering methods: given a number  $K$  of clusters and a measure of similarity, data (here daily situations) are grouped in  $K$  clusters such that the situations into a given cluster are as similar as possible, while situations in different clusters have to be very different. The clustering methods are widely used to study weather regimes [e.g., Yiou & Nogaj, 2004, Vrac et al., 2014 and the references therein]. In terms of SDMs those methods are rather used to condition statistical models, for example a stochastic model as in Schnur & Lettenmaier [1998], Bellone et al. [2000] or Vrac et al. [2007d].

In this study, the analog method is employed as representative of the WT family. This method considers each day as a cluster. A deterministic analog modelling as defined in Yiou et al. [2013] has been chosen here. It has been used in several previous studies [Zorita & Storch, 1999; Yiou et al., 2007; Vautard & Yiou, 2009; Chiriaco et al., 2014]. It consists in determining for a given day to be downscaled in the validation period the day in the calibration period which has the closest atmospheric situation. It is determined by a similarity metric between the predictor set of the day to be downscaled ( $X_V$ ) and the predictor set of the day in the calibration period ( $X_C$ ). This approach is quite flexible to change the distance or the temporal window of the situations [Yiou, 2014]. Many families of metrics can be used [e.g., Grenier et al., 2013] and one of them is distance:

$$\text{day}_{\in C} = \underset{\text{day}_{\in V}}{\text{argmin}} (\text{dist}(X_V, X_C)). \quad (6)$$

The Euclidian distance is chosen in this study. Only one experiment has been set and is called ANALOG. Note that one important difference

with the other models is that this method is applied over the entire predictor dataset anomalies, not only over the first two PCs. Hence, much more information than for the other models has been provided to this model, this will be discussed in SECTION 5.2. A threshold at 1 mm has also been applied to the output values for rainfall occurrences.

#### 3.1.5. Model output statistics (MOS)

This approach regroupes all the “quantile-mapping” related methods, more precisely all the methods relating the large-scale CDFs to the local-scale CDFs. For instance quantile-quantile based methods have been widely used for downscaling [e.g., Vrac et al., 2012 and references therein] or to correct bias in model outputs thanks to observations CDFs [e.g., Gudmundsson et al., 2012 and references therein] and the correspondences between predictors and predictands quantiles. Those methods can be directly calibrated on models outputs (e.g., GCM or RCM). Those correspondences can be based on non-parametric [Déqué, 2007] or parametric [Piani et al., 2010] models. Many methods have been implemented and compared in Gudmundsson et al. [2012]. The MOS technique used here is the “Cumulative Distribution Function-transform” (CDF-t) initially developed in Michelangeli et al. [2009] to downscale wind and applied later to temperature and precipitation, for example in Lavaysse et al. [2012], Vrac et al. [2012] and Vigaud et al. [2013].

The CDF-t model consists in relating local-scale (i.e., here E-OBS precipitation) CDF to the large-scale (i.e., here ERAi reanalysis precipitation) CDF. The CDF-t and quantile-quantile methods are similar in philosophy, except that CDF-t takes into account the change in the large-scale CDF from the calibration to the projection (or validation) time period, while quantile-quantile projects the simulated large-scale values onto the historical CDF to compute and match quantiles. Let  $\text{FRc}(x)$  and  $\text{FEc}(x)$  define respectively the rain CDFs from the Reanalyses (subscript R) and from E-OBS (subscript E) over the calibration period (subscript c) and  $\text{FRv}(x)$  and  $\text{FEv}(x)$  the CDFs over the validation period (subscript v). An estimation of  $\text{FEv}(x)$  is assumed to be:



Statistical Models Features											
Weather		MOS		Transfer Function				Stochastic			
Pattern Based		Bias Correction						Weather Generator			
ANALOG		CDFt-so		GAM		GAM-so		SWG		SWG-s	
Occ.	Pred.	Occ.	Pred.	Occ.	Pred.	Occ.	Pred.	Occ.	Pred.	Occ.	Pred.
T	Anom.	LR	ERAi PR	T	6 × 2PCs	LR	6 × 2PCs	LR	6 × 2PCs	COP	6 × 2PCs

Table 2: Statistical Downscaling Models features concerning the occurrence model (LR: logistic regression, COP: constant occurrence probability, T: thresholded) and the predictors (Anom.: anomalies over all the variables, ERAi PR: ERAi reanalyses precipitation, 6 × 2 PCs: the first two PCs of the five selected predictors and precipitation) used in each case.

$$F_{Ev}(x) = F_{Ec} \left( F_{Rc}^{-1} (F_{Rv}(x)) \right), \quad (7)$$

with  $x$  in the range of the physical variable of interest. Thus, the local-scale CDF over the validation period,  $F_{Ev}$  is obtained from the large-scale CDF  $F_{Rv}$  over the validation period, on which a transformation  $T$  defined from the CDFs over the calibration period,  $T(u) = F_{Ec} \left( F_{Rc}^{-1} (u) \right)$  is applied. Then, a quantile mapping between  $F_{Ev}(x)$  and  $F_{Rv}(x)$  is performed to retrieve the precipitation values at local scale. More detailed information, descriptions and evaluations of CDF-t are available in Vrac et al. (2012). CDFt-so is the only experiment set for this approach. In the same way as GAM-so, rain amount is modelled by CDF-t and rain occurrence by the LR. Because the ERAi precipitation presented too few days with precipitation amounts above 1 mm, CDF-t has been calibrated over precipitation above 0 mm. Indeed, too few rainy days (rain above 1 mm in that case) at the large-scale will produce too few rainy days in the downscaled data (not shown). That is why the calibration has been made for days above 0 mm and then the outputs have been thresholded at 1 mm. This model is the one which has the lowest quantity of information in terms of predictors: the large-scale precipitation only. Indeed the other models have six variables with precipitation among them. Computational details on CDF-t are available in “Appendix”.

### 3.2. Regional Climate Models

Concerning dynamical models, five runs have been selected: two from EURO-CORDEX and three from MED-CORDEX experiment. These simulations cover two different domains (FIGURE 1) but use the same horizontal resolu-

tion (0.44°) and are all initialised and forced at their boundaries by ERA-interim data. None of the models uses nudging inside the domain except IPSL-WRF311. A relaxation region of different widths (a few hundreds of km, depending on the model) is used to account for boundary imbalance effects. The common period of simulation is 1989–2008 and each model uses its own set of parameterizations. Details on each run can be found in the following references: Flaounas et al. [2013] for IPSL-WRF311, Nabat et al. [2014] for CNRM-ALADIN52 (see also Colin et al., 2010; Herrmann et al., 2011), Domínguez et al. [2013] and Jiménez-Guerrero et al. [2013] for UCLM-PROMES and Table 1 of Vautard et al. [2013] for IPSL-INERIS44 and for CNRM-ARPEGE51. These models are hereafter referred to as MED-IPSL, MED-CNRM, MED-UCLM, EURO-IPSL and EURO-CNRM respectively. As indicated in TABLE 3, CNRM and UCLM models repeat the year 1989 two or three times to take into account the spin-up associated to the surface scheme initialization. This is widely sufficient to equilibrate moisture in the levels of the soil that interacts with the atmosphere through evapotranspiration. Repeating the year 1989 two or three times is considered as negligible in the final results. IPSL models do not repeat this year but this does not influence the results. Indeed, year 1989 has been tested and similar behaviour compared to other years has been observed and several tests have shown that simulations were converging after a few days. Moreover, the use of nudging for the MED-IPSL simulations reduces the spin-up period. Besides, this investigation is beyond the scope of this paper.

TABLE 2 and 3 summarize all the models (SDMs and RCMs) and their features.

Dynamical Models Features					
Region	EURO-CORDEX		MED-CORDEX		
Model	WRF-IPSL-INERIS44	CNRM-ARPEGE51	IPSL-WRF311	CNRM-ALADIN52	UCLM-PROMES
Institute	IPSL and INERIS	CNRM	IPSL	CNRM	UCLM
Number of levels	32	31	28	31	36
Radiation scheme	RRTMG, Iacono et al. [2008]	Morcrette [1990]	RRTMG, Iacono et al. [2008]	Morcrette [1990]	ECMWF [2004] With fractional cloud cover Chaboureaud & Bechtold [2002] Chaboureaud & Bechtold [2005]
Convection scheme	Grell & Dévényi [2002]	Bougeault [1985]	Kain [2004]	Bougeault [1985]	Kain & Fritsch [1993]
Microphysics scheme	Hong et al. [2004]	Ricard & Royer [1993]	WSM 5-class Hong & Lim [2006]	Ricard & Royer [1993]	Hong et al. [2004]
Land-surface scheme	NOAH, Ek et al. [2003]	Douville et al. [2000]	RUC Smirnova et al. [1997]	Douville et al. [2000]	Krinner et al. [2005]
Boundary layer scheme	YSU, Hong et al. [2006]	Ricard & Royer [1993]	YSU, Hong et al. [2006]	Ricard & Royer [1993]	Cuxart et al. [2000]
Soil initialization and spin-up	Soil initialized from ERAInterim. No spin up	Year 1989 is played twice	Soil initialized from ERAInterim. No spin up	Year 1989 is played twice	Soil initialized from ERAInterim. Year 1989 is played three times
Land use	USGS Land Use	ECOCLIMAP	USGS Land Use	ECOCLIMAP	Assigned by the land-surface scheme

Table 3: Dynamical downscaling models features

## 4. Intercomparison results

The quality of the simulations is assessed by comparison to the data product considered as pseudo local-scale observations (E-OBS) in terms of rain occurrence and intensity, as well as spatial and temporal properties through selected indicators. In the view of the relatively equivalent results over the two seasons, only the results over the “summer” season will be presented hereafter. Besides, even if impacts studies generally need annual precipitation data, impact studies focusing for example on agricultural impacts, heat-waves or droughts studies need accurate precipitation data during spring and summer. Intense precipitation events around the Mediterranean usually take place between mid August and mid November and cause floods. Precipitation during winter is easier to model by the RCMs because of the stratiform nature of precipitation, whereas summer rainfalls are driven by convective rain processes, more difficult to represent and resulting from a parametrization in the RCMs. All the indicators are computed over the 1989–2008 period. Results specific for the “winter” season will be described and the corresponding figures are available as auxiliary material. In the following section, most evaluations are presented in terms of bias of the

indicators with respect to those of the pseudo-observations defined as “Indicator(simulation) minus Indicator(observation)”. In terms of colours, blue means that the model underestimates and orange/red means that it overestimates the considered criterion with respect to the observations.

### 4.1. Occurrence indicators

The evaluation begins by exploring the ability of the models to reproduce the occurrence properties: Do the models respect the observed proportions of wet or dry days and the time they occur? In this part, only nine models are considered for occurrence evaluation (ANALOG, GAM, LR, COP, EURO-CNRM, EURO-IPSL, MED-CNRM, MED-IPSL and MED-UCLM) since SWG, CDFt-so and GAM-so share the same LR occurrence model presented in EQUATION 1.

First, bias (in %) of wet days frequency have been investigated in FIGURE 3. The LR, COP and ANALOG models perform well. They show biases close to zero with very small positive or negative values and distributed over all the area. All the other SDMs and RCMs are strongly biased. Most of them are mainly positively biased which is a well known problem for RCMs: the models produce little rainfall amount too often [see Sun et al., 2006; Stephens et al., 2010 ].

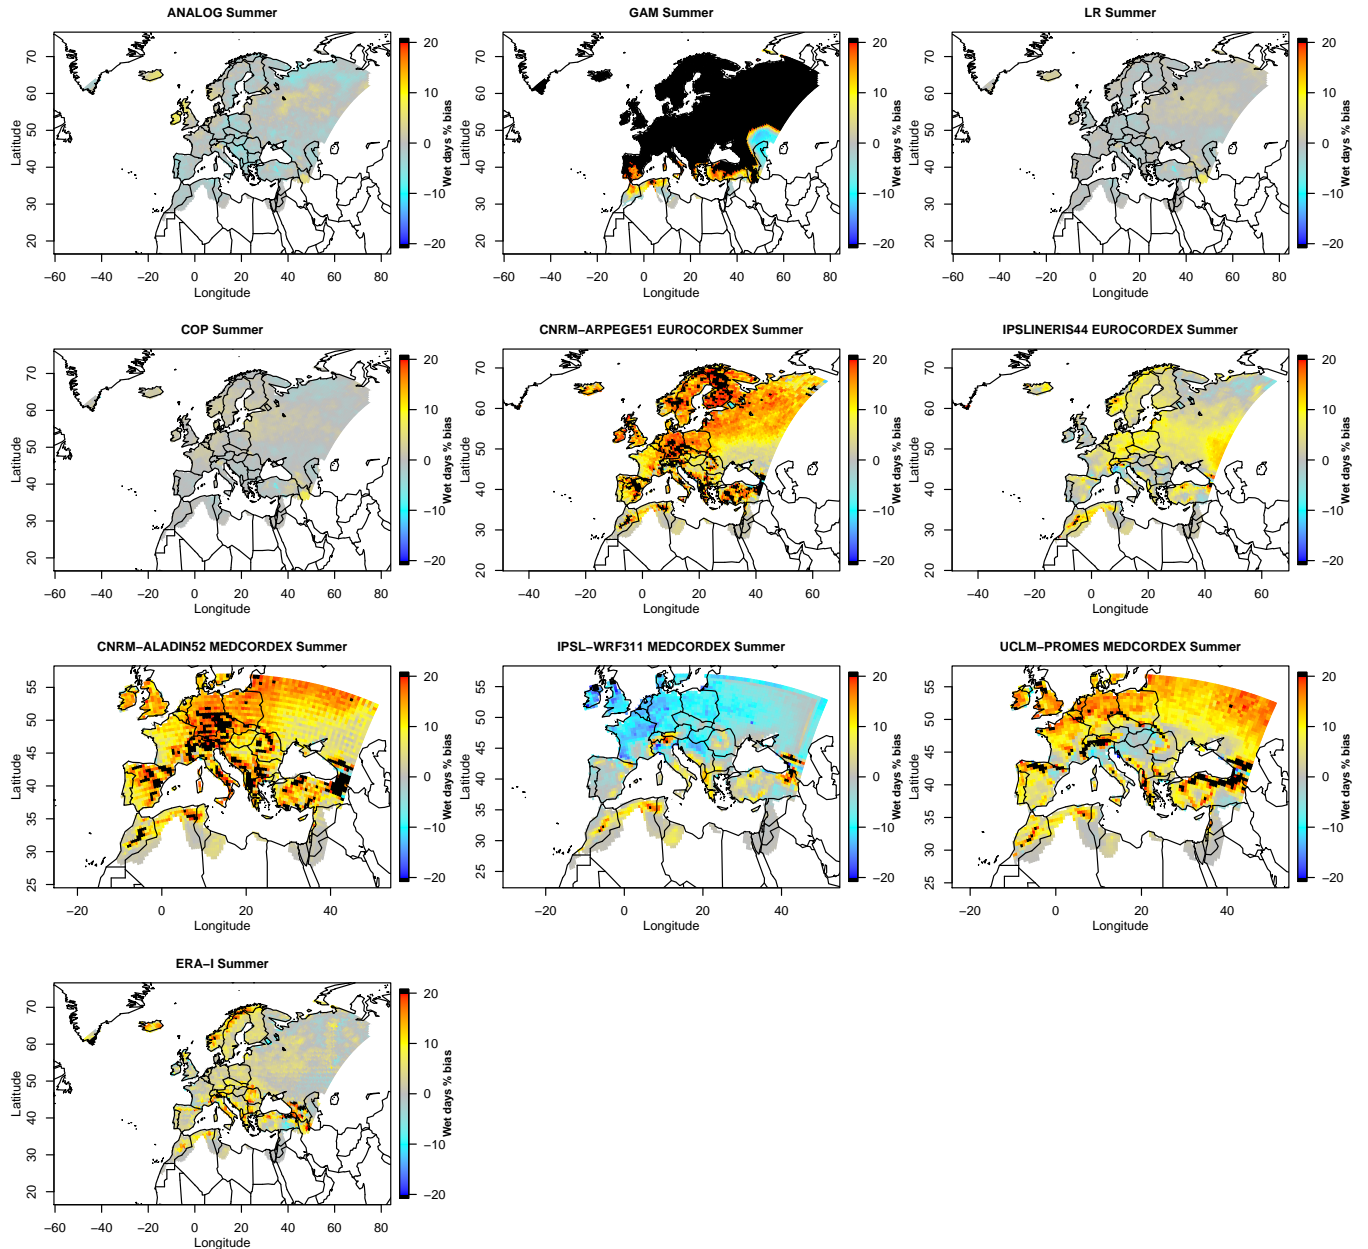


Figure 3: Wet day frequency bias in percentage (%). Some bias values have been saturated to ease the reading and to improve the color contrast: black means that the bias values exceed 20% in absolute values. The real range of values for each maps is given in auxiliary material TABLE 3 (*cf.* TABLE A.3).

The negative bias of MED-IPSL is due to land surface/atmosphere feedbacks that are not well reproduced generating dry soil too early in spring over most Western Europe then less clouds and precipitation and higher temperature in summer. Except ANALOG, LR and COP, all the models are globally producing rainfall too frequently. Both IPSL RCMs show patterns at the borders of the domain. This is a consequence of the relaxation zone at the domain boundaries. Similar patterns are observed on FIGURE 6 and 7 for the same reason. Note the very poor performance of GAM

which largely overestimates the percentage of rainy days.

For the winter season the results are more or less the same for all the models except for the EURO-CNRM model where the biases are smaller and distributed in terms of sign all over the domain. MED-IPSL presents also some interesting differences. The biases evolve from negative at the south-west to positive at the north-east of the domain (see auxiliary materials). This gradient is a consequence of a humidity bias observed in winter in the model (compared to GPS measures).

Indeed, there is a light positive humidity bias in Western Europe and it increases when going eastward. One explanation is that the microphysics scheme is not efficient enough for precipitation and can induce a lower precipitation amount for a given humidity rate. Besides, in winter the air mass flows from west to east which also increases the humidity and therefore the precipitation in the east.

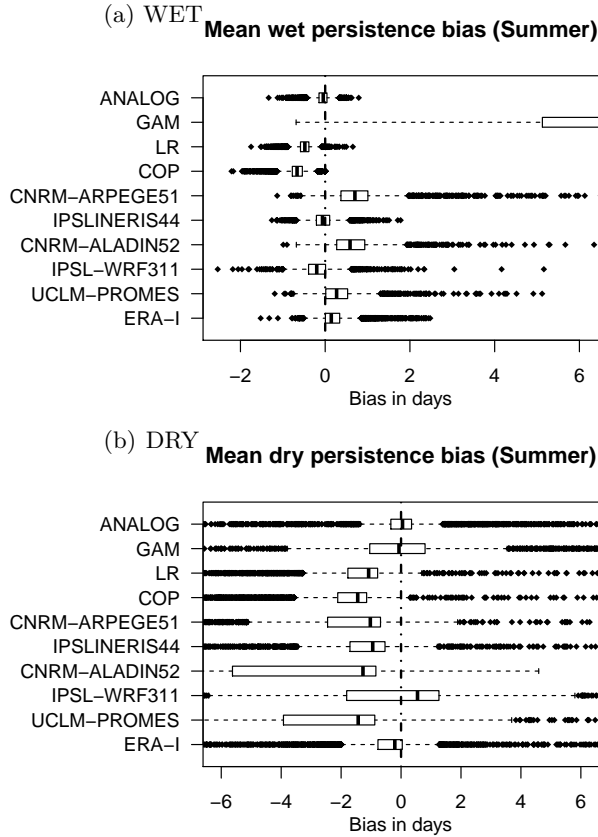


Figure 4: Mean wet and dry spells length bias in days for the summer season. The left and right fences are situated at 1.5 times the interquartile range from the box and the dots are the values beyond these fences. Bias values above 6 days or below -6 days have been ignored in these plots for readability reasons (*cf.* auxiliary material for the real range). **a** Wet spells bias. **b** Dry spells bias.

Periods of consecutive wet or dry days (or spells) have been also considered, in particular the mean length of the wet spells and dry spells biases (expressed in days). In other words, the mean wet and dry persistence biases are investigated. They are pictured by boxplots respectively in FIGURE 4a, b. In order to remain consistent with the domains presented in the maps of FIGURE 1, they are computed over different domains. These boxplots are nevertheless relevant since, when the indicators

are calculated only over the MED-CORDEX domain for all the models, the ranking of the models and the global aspects of the boxplots are similar (not shown). All the models except GAM show skills for reproducing the wet spells of E-OBS, especially the EURO-IPSL and ANALOG models. On the opposite, GAM is strongly biased. Interestingly, although not perfect, the LR occurrence provides better results than the constant occurrence probability (COP) approach. In other words, the non-stationarity brought by the logistic regression improves the wet occurrence modelling compared to the stationary COP model. Concerning the mean dry spells, the models uniformly underperform (*i.e.*, they present larger biases) than for mean wet spells. They all have also difficulties to reproduce dry spells around the Mediterranean (not shown). They mainly underestimate the mean dry spell length except for MED-IPSL. The mean wet and dry spells biases do not cancel each other even if the MED-CORDEX models, GAM and EURO-CNRM show opposite bias signs between wet and dry spells. In other words, a deficit (or an excess) of the wet days persistence does not necessarily imply an excess (or a deficit) of the dry days persistence. In winter, the results are similar except that the mean wet spells biases absolute values are smaller for all the models (see auxiliary materials).

Until now, the rain occurrence has been tested only in terms of frequencies.




Figure 5: Brier score: the scores boxplots of each models are represented between 0 and 1. Models with scores close to zero have good estimation of the daily rain occurrence probabilities

In order to characterize the time synchronicity of the rainy events, the Brier score [hereafter referred

to as BS, Brier, 1950 ] is computed. The BS describes how close to the daily observed occurrences the daily estimated probabilities are:

$$BS = \frac{1}{N} \sum_{t=1}^N (p_t - o_t)^2, \quad (8)$$

where  $p_t$  is the estimated probability at the time  $t$  from LR and 1 or 0 for deterministic models for rain or no rain respectively,  $o_t$  is the observed occurrence in observation at time  $t$  which takes the values 1 or 0 (meaning rain or no rain) and  $N$  is

the number of days. Hence, the closer the score to 0, the more synchronized the model is. FIGURE 5 shows the scores computed for each model. LR and MED-IPSL have the smallest values, on average below 0.2. The other models, except GAM and ANALOG, have a BS on average below 0.4. Note that the Analog approach has better results in terms of rainy days proportion than for the timing of rainfall events. This means that the Analog model produces sequences of wet or dry days with correct proportions but not at the right moment.

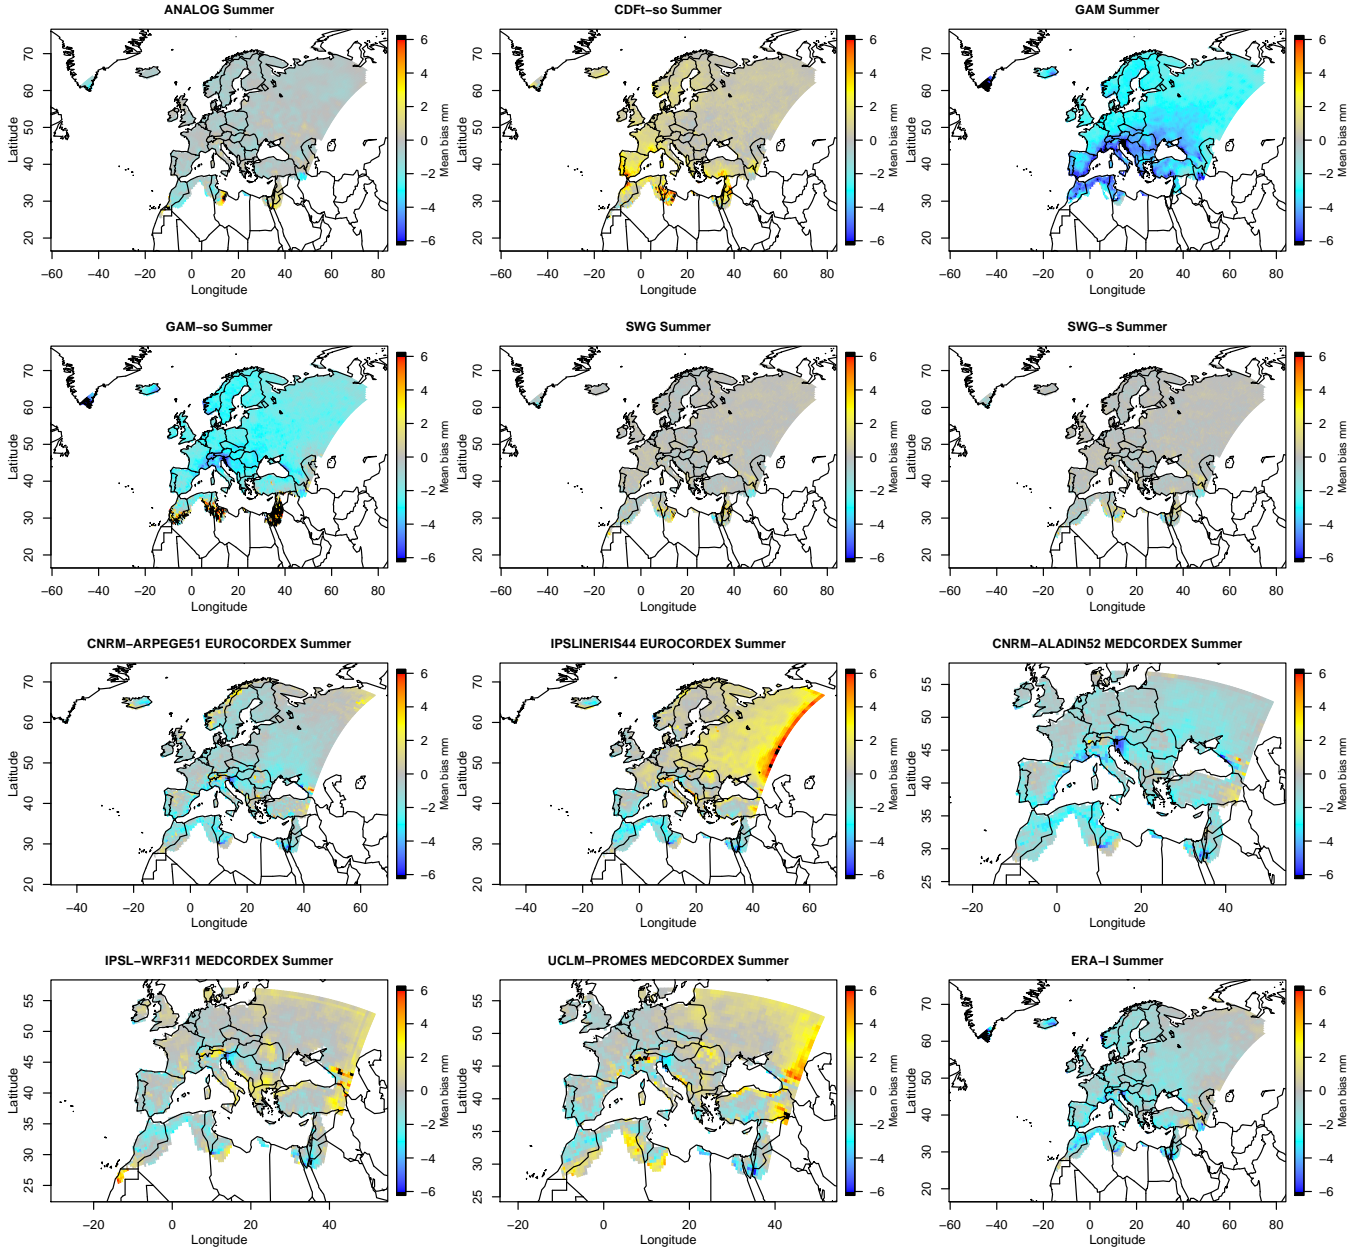


Figure 6: Mean precipitation bias in  $\text{mm}\cdot\text{day}^{-1}$ . Bias values above 6 mm or below -6 mm have been saturated in black in order to have a good color contrast (*cf.* auxiliary material for the real range).



In winter (see auxiliary materials), the results are similar.

#### 4.2. Intensity indicators

The statistical properties of the downscaled rain intensity at individual grid-points of the 11 models are now compared to those of the observations. Figure 6 shows mean daily precipitation biases (in mm) for the precipitation above 1 mm. The average rain amounts are well represented by SWG, SWG-s, ANALOG, CDFt-so models. CDFt-

so shows small positive biases over almost the whole domain while SWG, SWG-s and ANALOG models present small positive and negative biases distributed all over the domain. GAM, GAM-so and the dynamical models are more or less strongly positively and negatively biased. MED-IPSL is the best among them with positive and negative biases distributed all over the domain which is also the case for MED-UCLM. EURO-CNRM, MED-CNRM present mostly negative biases while EURO-IPSL has mostly positive ones.

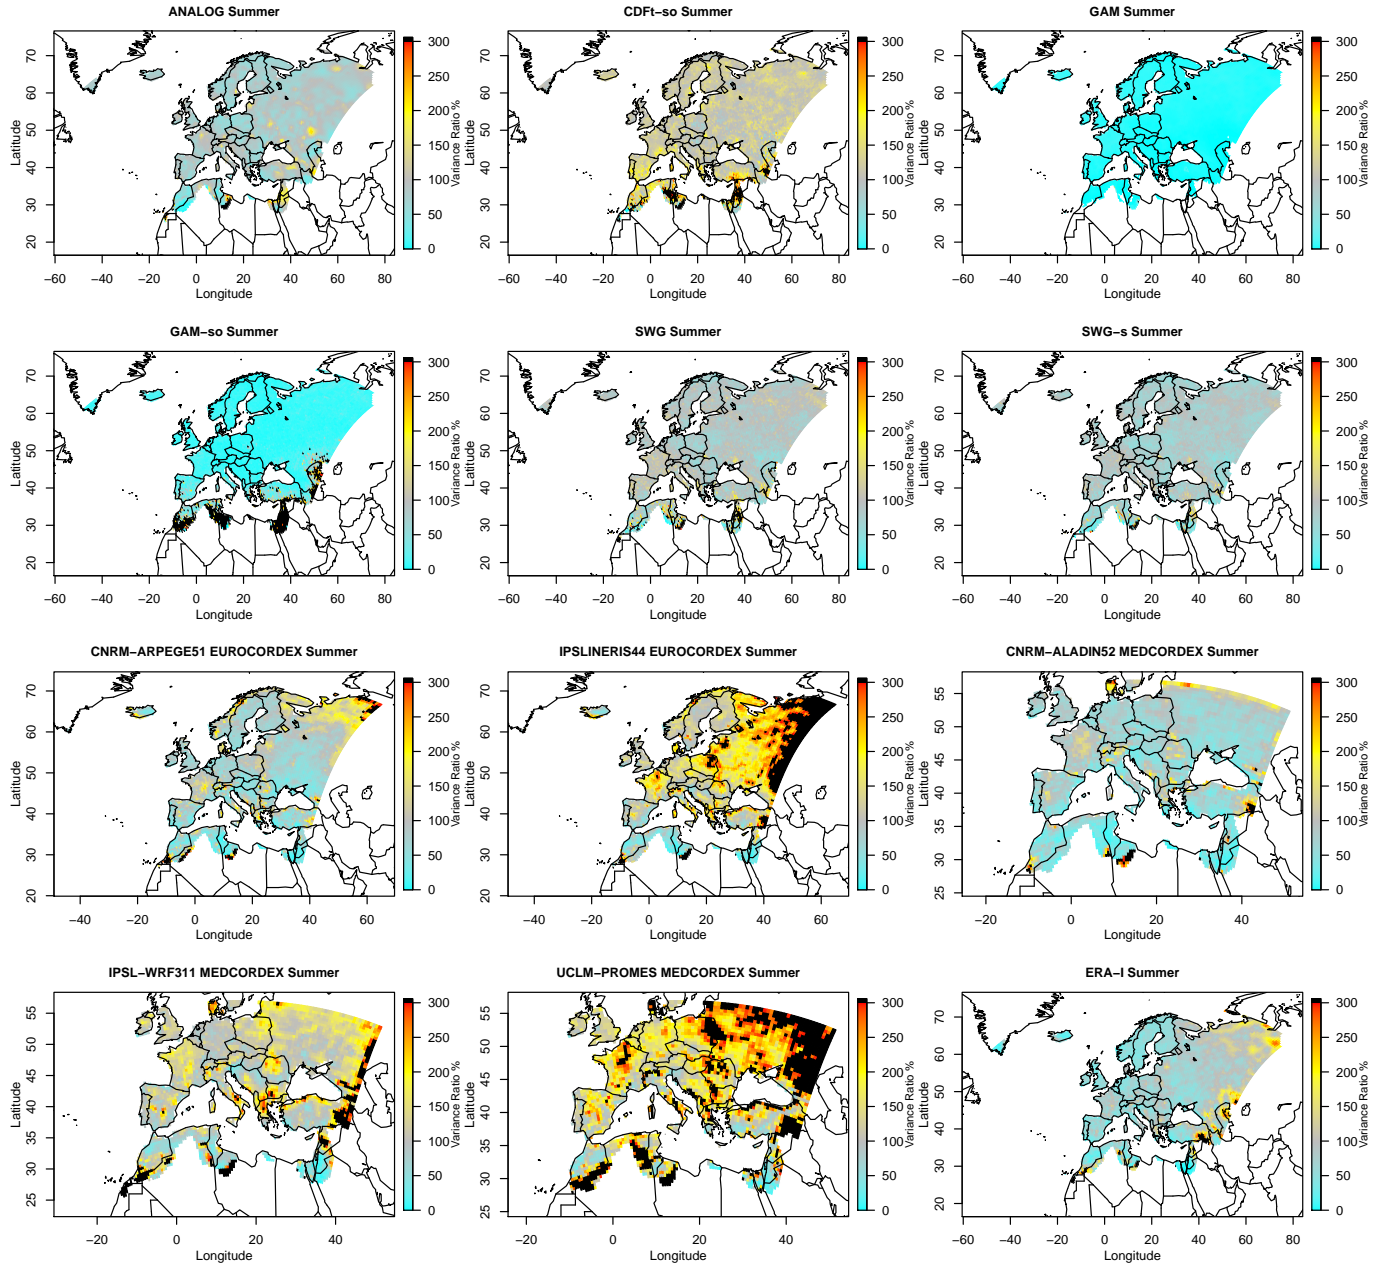


Figure 7: Variance ratio in percentage (%). Values above 300% have been saturated in black for the same reason as previously (*cf.* auxiliary material for the real range).

Border patterns are visible for all the RCMs which are a consequence of the relaxation zone. Similar results are found for winter although with smaller biases for all the models except MED-IPSL (see auxiliary materials).

FIGURE 7 displays the variance ratio (in percentage). It is the ratio between the variance of the simulations and that of the observations:

$$\%rv = \frac{\sum_{i=1}^n (S_i - \bar{S})^2}{\sum_{i=1}^n (O_i - \bar{O})^2} \times 100, \quad (9)$$

with  $S_i$  is the simulated value for day  $i$ ,  $O_i$  is the observed value at day  $i$ ,  $\bar{O}$  is the mean of the observations for the period, and  $\bar{S}$  is the mean of the simulated data. While CDFt-so performs well with some variations and mostly overestimates the variance over the area, ANALOG, SWG and SWG-s tend to underestimate the variance. For the stochastic models, it is caused by the way rain amounts have been simulated. Indeed, the SWG and SWG-s models have been forced to simulate precipitation above 1 mm which can reduce the variability of the generated data. Once again GAM and GAM-so perform poorly. While the other SDMs reach an average ratio between 80 and 150 %, GAM and GAM-so barely reach 25 % and are the worst among all models. Concerning RCMs, CNRM models are the best among them although they mainly underestimate the variance around 80 %. Others are much more biased and mostly overestimate it. Their variance ratios are above 150 %. Here, the patterns at the boundaries for RCMs are stronger than for the previous indicators. In winter, the SDMs have the same behaviour unlike RCMs. CNRM models and MED-IPSL present variance ratio larger than for summer: closer to 100 % for CNRM models and ratios above 150 % for MED-IPSL (see auxiliary materials).

As a last indicator of marginal intensity, the reproduction of extreme values is investigated. The 99th quantile bias (in mm) is considered and shown in FIGURE 8. Overestimation and underestimation patterns are quite similar to those observed for the variance ratio (see FIGURE 7) transposed to the 99th quantile bias i.e., biases are quite similarly distributed all over the area (not shown). Thus, similarly to the variance ratio ANALOG, CDFt-so, SWG and SWG-s are good to reproduce extremes. ANALOG, SWG and SWG-s slightly

underestimate the 99th quantile, while CDFt-so overestimate it. Note that MOS models like CDFt may be unstable to simulate extremes especially for future projections. In order to deal with this issue, the constant correction method defined in Déqué [2007] is used in CDF-t. The underestimation for SWG and SWG-s results from the marginal Gamma pdf used here which is not able to reproduce correctly the extremes. This is something known and investigated in literature [e.g., Vrac & Naveau, 2007]. GAM and GAM-so reach a median bias below -10 mm and therefore widely underestimate the 99th quantile. RCMs over- or underestimate depending on the model. CNRM RCMs present mostly negative biases and the others positive biases.




Figure 8: 99<sup>th</sup> quantile bias in mm. Bias values exceeding 20 mm in absolute values are not represented (cf. auxiliary material for the real range).

In winter (see auxiliary materials), the results are similar except that biases are smaller in absolute values. The only remarkable difference is for CNRM models which present mostly positive 99th quantile bias.

#### 4.3. Spatial indicators

The spatial properties of the downscaling models, more precisely the spatial variability are now evaluated. To this end, a PCA is performed on daily downscaled precipitation outputs for each of the 11 models and on E-OBS data. FIGURE 9 pictures the first summer EOF of E-OBS and of each model. Since the distribution of precipitation is skewed, and therefore non-Gaussian, a transformation of the precipitation data has to be performed before applying a PCA. Here, the approach suggested by Vrac & Friederichs [2015] is followed: the zero precipitation values have been set to a small value different from zero (0.00033) and we

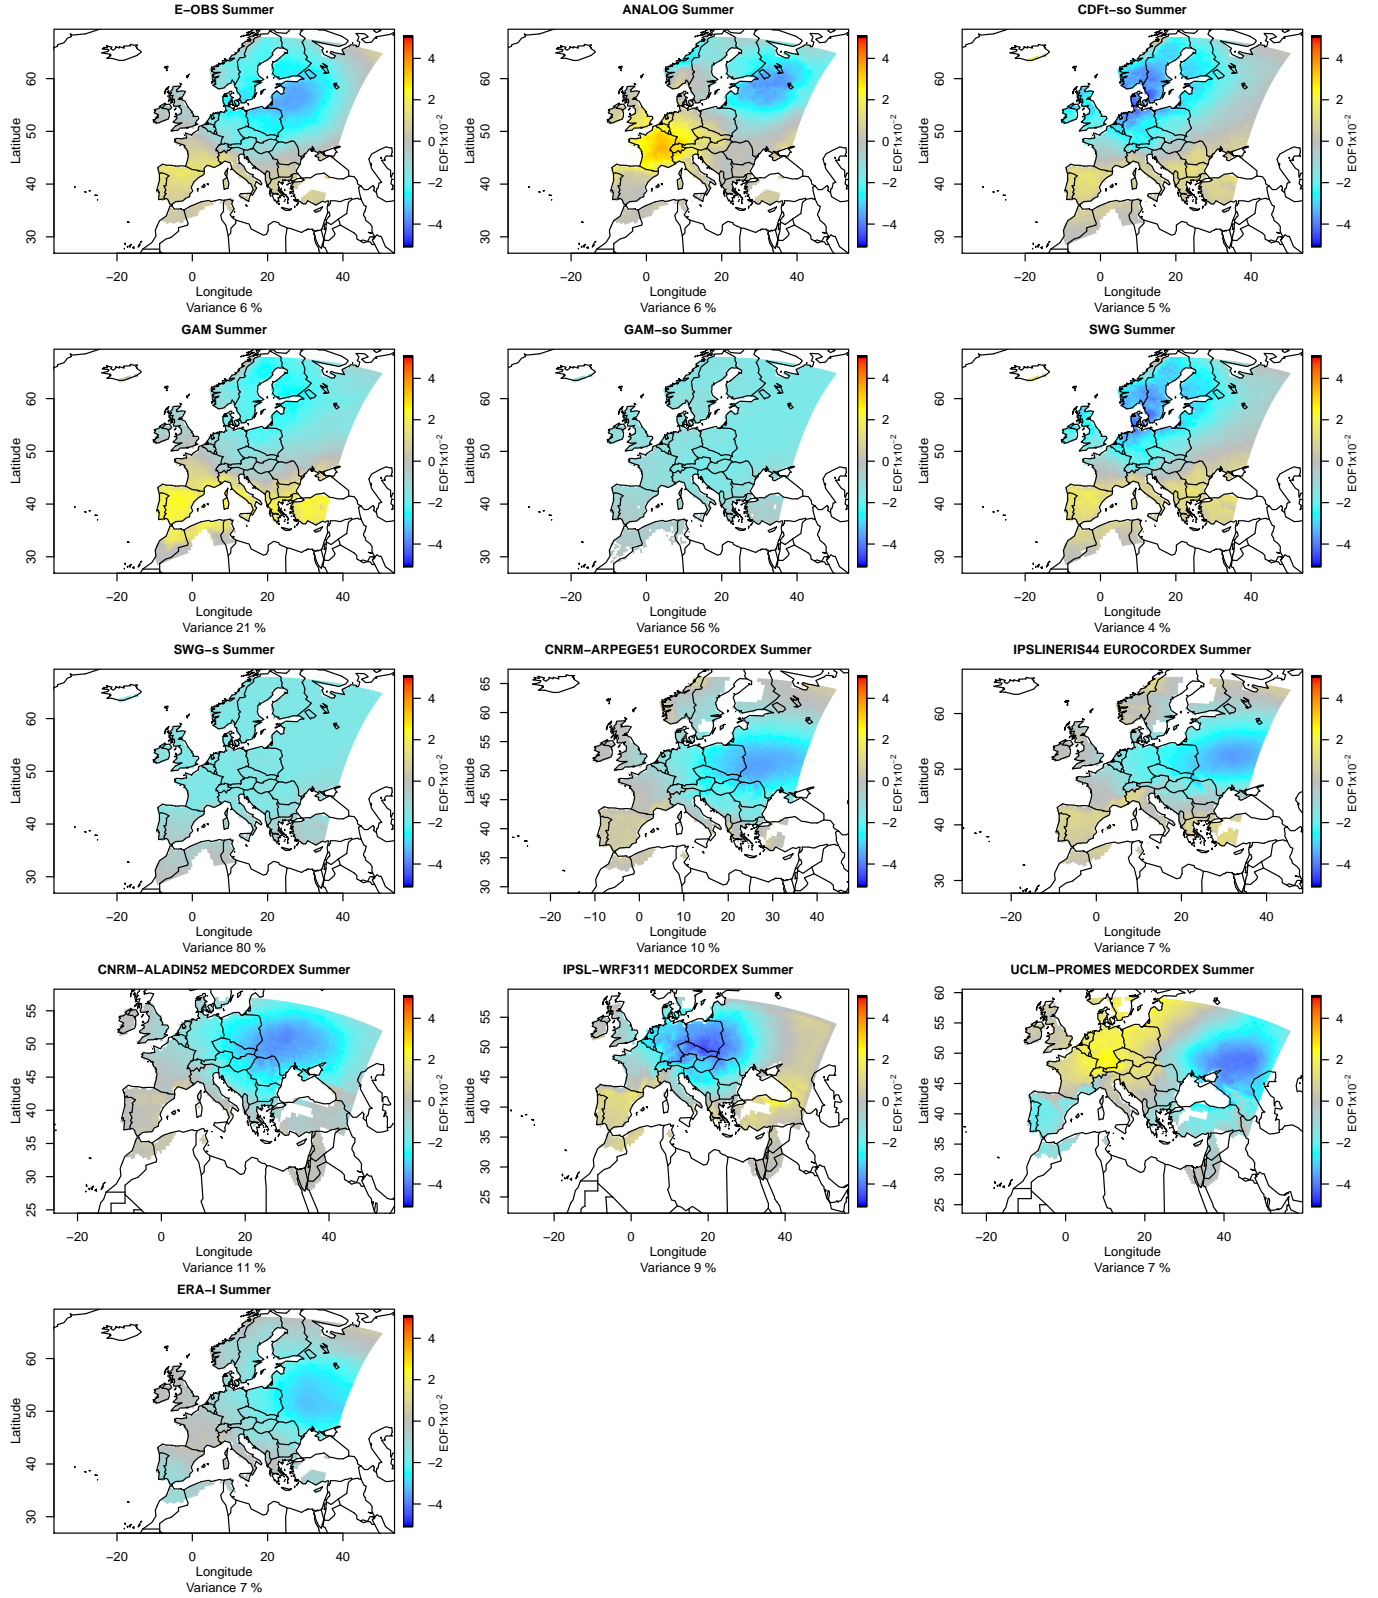


Figure 9: Spatial distribution of the first EOF loadings of each models. The variance explained by each EOF is indicated for each model.

then computed the logarithm of all precipitation data, with 0's transformed to 0.00033. The PCA is actually performed on those transformed precipitation outputs. The variance explained by the first EOF is indicated for each model. Even if

the values are generally low (mostly around 10 %), in the present case, it is a valuable tool to spatially compare modes of variability. The EOF coefficient characterizes the contribution of each grid-point to the variability explained by a PC.



The aim is to see if the EOF values for each model have the same spatial distribution as for E-OBS. Similar patterns means that the models have a good ability to reproduce the spatial variability of the observations. The ANALOG model has almost the same spatial structure as the observations. This was expected since ANALOG is based on a resampling procedure and therefore keeps the spatial structure. The other statistical models have quite different spatial patterns even if CDFt-so, GAM and SWG are quite close. In some cases, they even present “flat” spatial patterns (i.e., EOF coefficients are almost equal). The “flat” spatial patterns come from models that are not able to reproduce any spatial variability in their simulations. That is the case for GAM-so and SWG-s for example, whose simulations are made pointwise without spatial constraints. EURO-CORDEX models well reproduce the observation pattern whereas MED-CORDEX models. In winter (see auxiliary materials), the spatial variability of all the models is better caught than in summer, except for GAM-so and SWG-s again. It is probably a consequence that the rain processes involved are different depending on the season. In winter the precipitation is stratiform or dynamic which is related to large-scale atmospheric system. In summer, the precipitation relies on convective processes (*i.e.* isolated storms for instance) which have a complex spatial structure.

The pattern correlation of the daily maps has also been investigated. It was computed between the previously transformed precipitation outputs used to compute the EOF and the transformed E-OBS. In FIGURE 10, the boxplots of daily pattern correlation are given. RCMs—which are spatially constrained—are better than SDMs. Even ANALOG, which is considered as efficient for reproducing the spatial variability, fails in reproducing daily spatial pattern. It is consistent with the result given by the Brier score which indicates that ANALOG fails in terms of synchronicity of the events. The best model is the MED-IPSL model; this might be explained by the fact that it is nudged. Note that ERAi presents the best pattern correlation with E-OBS, with the exception of MED-IPSL. Even if MED-IPSL model is

nudged with ERAi, it seems to improve the pattern correlation of MED-IPSL with E-OBS.

#### 4.4. Temporal indicators

The temporal aspect is studied through two angles: by studying the interannual variability and studying the seasonality. Naturally these indicators are examined over the whole year.

In FIGURE 11, the cumulated annual rain amount over two illustrative stations (see FIGURE 1 for their location): Montpellier (FIGURE 11a) and Moscow (FIGURE 11b) is represented. The top panels display the E-OBS amounts, all the statistical models and ERAi, while the bottom panels show the results from the dynamical models and E-OBS. The reanalysis precipitation is plotted since it is the only predictor of CDFt-so. First, the case of Montpellier is considered: among statistical models all deterministic models (in purple) except GAM-so seem to be better than the stochastic models (in green) to reproduce the inter-annual variability. GAM-so annual amounts are low because of the combination of LR to model rain occurrence and GAM to model rain intensity. The latter is designed to simulate the average rain amount but the random trial for the rain occurrence reduces the annual amount. The dynamical models are better than the statistical models for the inter-annual variability (except ANALOG and CDFt-so).




Figure 10: Pattern correlation of daily maps between each models and E-OBS

For Moscow, the evaluation result is quite different. In this case, no SDMs seem to reproduce the inter-annual variability of the observations. As for Montpellier, low annual rainfall amounts are observed for GAM-so. Almost all dynamical models

overestimate precipitation for this station except EURO-CNRM which is particularly close to E-OBS in this case. In order to have a more global overview over the domain, the correlation between cumulated annual rain amount time series of each model and that of E-OBS have been computed pointwise. The boxplots of the correlations are available in FIGURE 12. Obviously the SDMs have difficulties to reproduce the inter-annual variability compared to the RCMs except the CDFt-so whose predictor is ERAi total precipitation (*cf.* the boxplot of total precipitation above 1 mm of ERAi in FIGURE 12). The performance of the other SDMs is poor (with correlation from 0.2 to 0.4) and the stochastic models and ANALOG have

the worst performance while they were the best for occurrence and intensity marginal properties. RCMs are more satisfactory, especially the EURO-CNRM and MED-IPSL models. However, these results have to be considered carefully because they characterize the year-to-year synchronisation of the variability i.e., if the variations of the annual amount increase or decrease at the same moment. In terms of RMSE (given in auxiliary material) SDMs are better than RCMs (except GAM-so) as already suggested by the evaluation of the Brier score. This observation does not stand for EURO-CNRM, which is good in terms of RMSE and correlation but not for the Brier score.

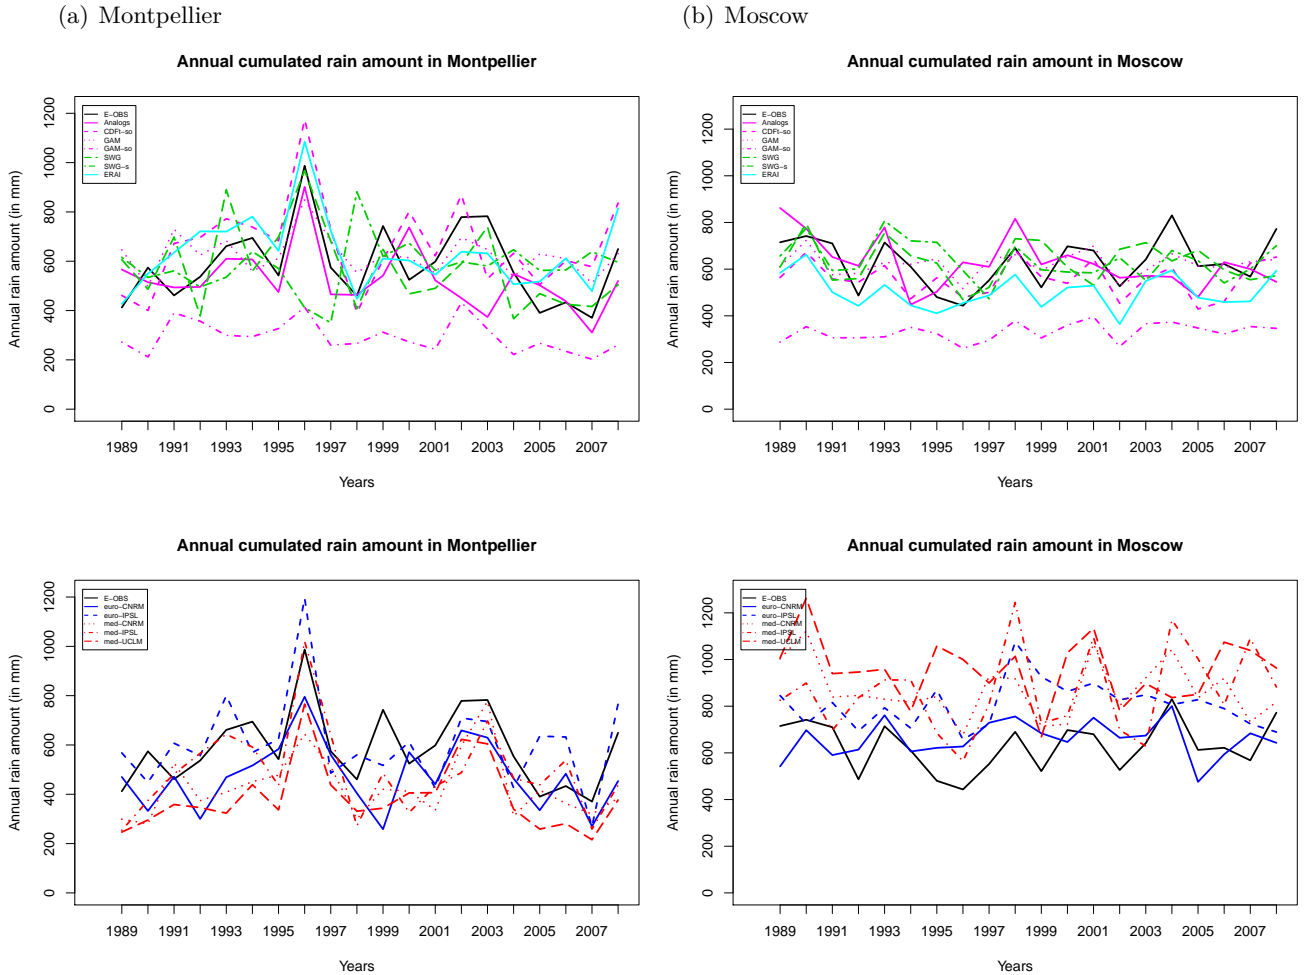


Figure 11: Annual rain amount in  $\text{mm}\cdot\text{year}^{-1}$  of the models, *left* for Montpellier and *right* Moscow. *Top panels* regroup all the SDMs, ERAi and E-OBS, *bottom panels* all the RCMs and E-OBS. **a** Montpellier, **b** Moscow

Now the seasonality is examined. To this end, the daily mean of each month (including zeros) over the 20 years is computed (i.e., 12 values, one

for each month) for each model and E-OBS. Then the correlation between the seasonal cycle of each model and E-OBS is calculated. FIGURE 13 shows

the corresponding boxplots. Here the results are opposite compared to the previous figure when comparing SDMs and RCMs. This time SDMs achieve higher correlation (except SWG-s), reaching correlations around 0.9 while RCMs have more troubles to reproduce the seasonal cycle, reaching correlations around 0.75 nevertheless. In the case of MED-IPSL, the bad seasonal cycle is partly a consequence of the land surface/atmosphere feedbacks described in SECTION 4.1.

A third index has been considered to evaluate the temporal properties. In FIGURE 14, the first order summer autocorrelation coefficients (AR1) for each model are pictured. As for the first EOF, the aim is to see if the spatial distribution of the coefficients of each model is the same as for E-OBS. The AR1 coefficient is computed over the precipitation outputs gaussianized as in SECTION 4.3. GAM gives too high autocorrelation due to




Figure 12: Boxplots of the correlation coefficients between annual rain amount time series of each models and E-OBS.




Figure 13: Correlation coefficient between the seasonal cycle of each models and E-OBS

the fact that it generates a little amount of rain too frequently. Other SDMs have very low auto-

correlation except the ANALOG which reproduces closely the autocorrelation of observations. Note that the CDFt-so model achieve very different AR1 coefficients than ERAI coefficients, it is a consequence of the LR used for the occurrence of this model. This widely modify the rain occurrence observed in ERAI and therefore influence the autocorrelation. RCMs have autocorrelation values different from that of the observations but are very close to E-OBS in terms of range. The 2-day and 3-day-lag-autocorrelation values have also been computed (not shown), these coefficients decrease quite fast as expected for rain and the ranking of the models compared to E-OBS is the same as for AR1. In winter (see auxiliary materials) the results are similar for SDMs. RCMs are globally much better and their autocorrelation coefficients are really close to those computed for E-OBS.

## 5. Conclusions and discussions

### 5.1. Conclusions

In this study, an intercomparison of several precipitation downscaling models has been conducted. To this end, an intercomparison framework has been built following some essential requirements. First, all the models had to have common predictors (as much as possible) coming from the same database, here ERAI reanalyses. Second, observations and models outputs with the same spatial resolution and over a common area were considered. So, considering the available RCMs and observational data resolution (E-OBS), a resolution at  $0.44^\circ$  has been chosen. Third, the selected models had to represent all the downscaling approaches the authors have defined (TF, WG, WT, MOS statistical families and some dynamical models). So 11 models (six SDMs and five RCMs) have been selected and their outputs confronted according to criteria characterizing the four following aspects of the rain: occurrence, intensity, as well as spatial and temporal properties. This study is an opportunity to set-up and test the consistency of the intercomparison framework to compare outputs coming from SDMs as well as RCMs. Very different downscaling models, at least in terms of model philosophy, have been compared.

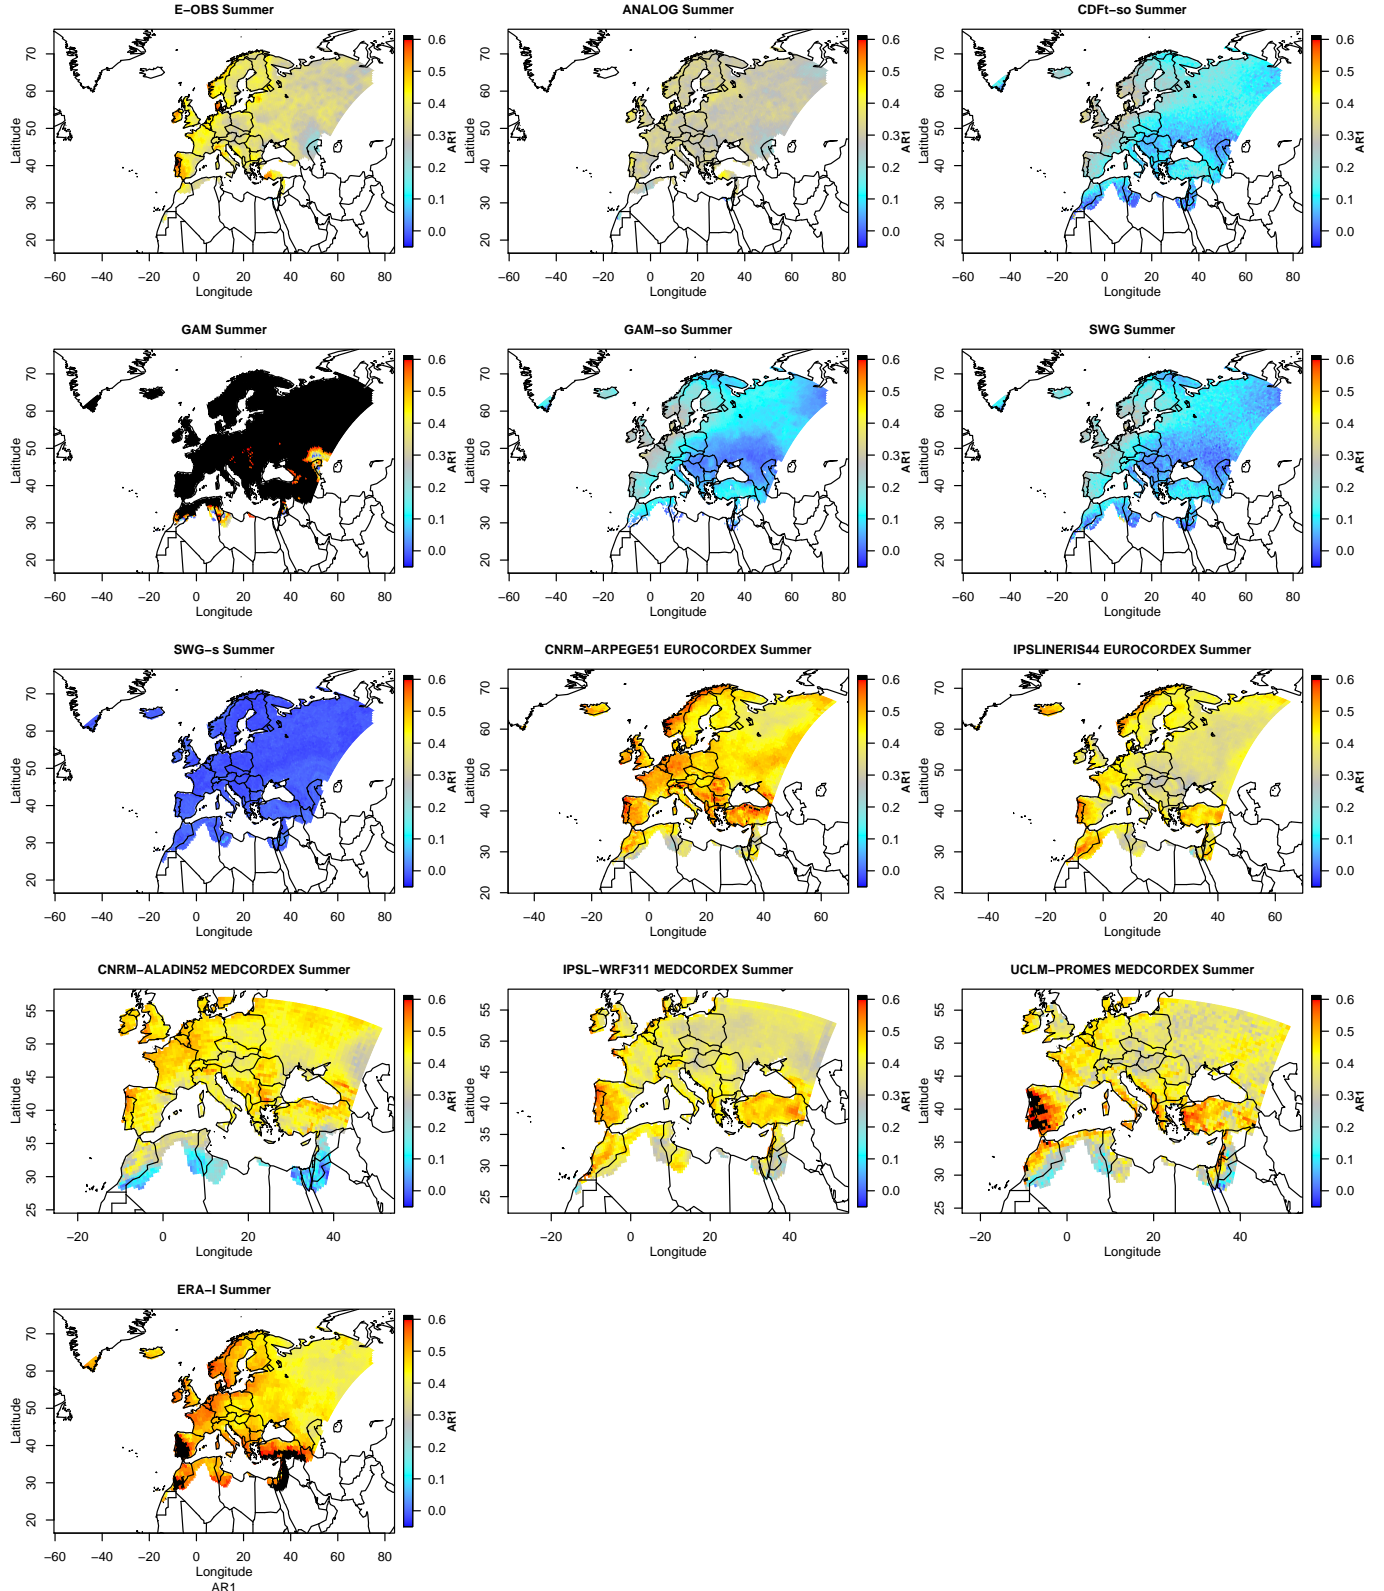


Figure 14: First order autocorrelation coefficient for each models. Only values below 0.6 are represented, above they are saturated in *black*.

All the RCMs (except MED-IPSL), as well as GAM, seem to produce too many rainy days. For general consideration, modelling the rain occurrence by an LR (logistic regression) reveals itself to be a better approach than thresholding the

outputs. Concerning the spells, all the models have better abilities to reproduce the wet spells than the dry ones and ANALOG is the best to reproduce them. However, even if ANALOG is to be a better approach than thresholding the

good in terms of occurrence statistics, it fails in terms of time accuracy (Brier score).

The second examined aspect is the rain intensity. Here, the mean climatology is better reproduced by the stochastic models (SWG and SWG-s). While variability and extremes are better dealt by ANALOG and CDFt-so, SWG and SWG-s are close behind. All the other models present strong biases with variations over the domain. GAM-so and GAM completely fail in reproducing intensity properties. This is in agreement with Schoof & Pryor [2001] concerning TFs models performances. Concerning RCMs, the study corroborates the classical results found in the literature, namely that they are producing too many rainfall events (occurrence) but with low intensity [Sun et al., 2006; Stephens et al., 2010] except for MED-IPSL.

Spatial pattern are studied through two specific angles: first, the spatial variability thanks to an EOF analysis; second the pattern correlation of the daily maps. Concerning the spatial variability the ANALOG and EURO-CORDEX, are better reproducing E-OBS spatial rain patterns while the others show quite different or no patterns at all. The models with good spatial pattern are the models which have spatial constraints: by construction for RCMs and by keeping the observations spatial structure for ANALOG model. This shows the importance of developing statistical spatial models in the future. In terms of daily pattern correlation, the only model which has been nudged, MED-IPSL, is the best to achieve the daily pattern of E-OBS (even if the nudging has been done with ERAi).

Finally the temporality was investigated. In this study, SDMs fail to retrieve E-OBS inter-annual variability especially SWG and SWG-s models. It is probably due to the random nature of the simulations which can generate too large or too little rain amounts and thus simulate very different annual rain amount compared to the observations. Another explanation could be the lack of information in terms of inter-annual variability provided by the predictors. RCMs on the opposite are in general better with a good performance of EURO-CNRM and MED-IPSL. For several aspects, MED-IPSL model achieve good performances. This can be partly explained by the nudging performed in-

side the domain with ERAi. In the mean time, the SDMs succeed in reproducing the seasonality. RCMs have more difficulties to achieve a good seasonal cycle. Finally, in terms of autocorrelation, ANALOG, followed by the RCMs are close to the E-OBS autocorrelation. Other SDMs, are quite far from E-OBS autocorrelation values.

In order to synthesize the results, the statistical models and the dynamical models are ranked according to each criterion. The models are scored according to the domainwide averaged indicators in TABLES 4 and 5 over MED-CORDEX and EURO-CORDEX domain respectively: the lower the score, the better the model. A global score can be obtained by simply adding each indicator rank over each of the considered aspects of the model evaluation (occurrence, intensity, spatial and temporal). TABLES 4 and 5 can be used as a guideline for the users of the simulations. It allows to choose the model(s) to be used, depending on the needed statistical properties that the simulations must satisfy for some particular applications. Indeed, there is not one model in particular which really takes the advantage on the others considering the four aspects of the evaluation. Their performances really rely on the considered indicators and therefore on the use of the model simulations. Thus, the model quality depends on the end-users needs and the properties they expect the data to have to define their “best” model.

## 5.2. Perspectives and discussion

Many perspectives can be foreseen for this work. The choice between SDM and RCM methods can not be done solely on the reproduction of ERAi climate. A direct continuation can be the inter-comparison in a future climate context. First, the couple “GCM/SDM” over the historical (or CTRL) period has to be evaluated. From the SDMs fitted over the historical period (e.g., 1979–2008) to the observations (E-OBS) and reanalyses (ERAi) (i.e., basically similar to which has been done in this study), new time series driven this time by GCMs as predictors will be generated and evaluated. A good agreement of those time series with observations would mean that GCMs provide good predictors to simulate local-scale variables. Thus, the ability of the SDMs to reproduce the climatological present characteristics of the precipitation

Model	ANALOG	CDFt-so	GAM	GAM-so	SWG	SWG-s	EURO-CNRM	EURO-IPSL	MED-CNRM	MED-IPSL	MED-UCLM	ERA-I
Wet days % bias	-1.04(3)	-0.29(2)	32.87(9)	-0.29(2)	-0.29(2)	0.02(1)	10.75(7)	4.10(5)	11.19(8)	-2.80(4)	8.33(6)	3.66
Wet mean persistence	-0.09(2)	-0.50(5)	9.01(9)	-0.50(5)	-0.50(5)	-0.66(6)	0.72(8)	-0.02(1)	0.66(6)	-0.17(3)	0.34(4)	0.24
Dry mean persistence	-28.13(8)	-14.97(2)	286.75(9)	-14.97(2)	-14.97(2)	6.28(1)	-25.98(5)	-26.38(6)	-27.37(7)	-21.57(4)	-16.70(3)	-16.17
Brier Score	0.26(6)	0.14(1)	0.37(9)	0.14(1)	0.14(1)	0.16(3)	0.28(8)	0.26(6)	0.23(4)	0.15(2)	0.24(5)	0.14
<b>Total Rank Occurrence</b>	<b>19</b>	<b>10</b>	<b>36</b>	<b>10</b>	<b>10</b>	<b>11</b>	<b>28</b>	<b>18</b>	<b>25</b>	<b>13</b>	<b>18</b>	<b>-</b>
Mean bias mm	-0.26(6)	1.18(9)	-3.74(11)	-0.15(3)	0.16(4)	-0.01(1)	-1.08(8)	0.33(7)	-1.26(10)	-0.06(2)	0.19(5)	-1.47
Variance Ratio%	88.45(2)	146.71(7)	2.65(11)	42.09(10)	98.93(1)	82.79(3)	80.56(4)	166.53(8)	75.52(5)	140.27(6)	224.06(9)	76.97
Q99 bias mm	-2.57(2)	4.00(7)	-21.90(11)	8.45(9)	0.17(1)	-3.01(5)	-2.85(3)	5.23(8)	-3.18(6)	2.85(3)	10.99(10)	-4.04
<b>Total Rank Intensity</b>	<b>10</b>	<b>23</b>	<b>33</b>	<b>22</b>	<b>6</b>	<b>9</b>	<b>15</b>	<b>23</b>	<b>22</b>	<b>11</b>	<b>24</b>	<b>-</b>
EOF1	1	2	4	11	2	11	6	6	6	5	10	-
Spatial pattern correlation	0.23(8)	0.27(8)	0.32(6)	0.28(7)	0.19(10)	0.11(11)	0.36(4)	0.36(4)	0.49(2)	0.62(1)	0.41(3)	0.53
<b>Total Rank Spatial</b>	<b>9</b>	<b>10</b>	<b>10</b>	<b>18</b>	<b>12</b>	<b>22</b>	<b>10</b>	<b>10</b>	<b>8</b>	<b>6</b>	<b>13</b>	<b>-</b>
Cor. Annual Amount	0.26(9)	0.46(4)	0.34(7)	0.27(8)	0.20(10)	-0.10(11)	0.43(5)	0.37(6)	0.58(2)	0.63(1)	0.50(3)	0.69
Cor. Seas. Cycle	0.80(3)	0.81(2)	0.87(1)	0.75(5)	0.80(3)	0.58(9)	0.58(9)	0.61(7)	0.61(7)	0.49(11)	0.68(6)	0.85
AR1 (E-OBS:0.38)	0.31(6)	0.12(7)	0.68(10)	0.11(8)	0.10(9)	0.00(11)	0.46(5)	0.41(4)	0.37(2)	0.39(2)	0.38(1)	0.52
<b>Total Rank Temporal</b>	<b>18</b>	<b>13</b>	<b>18</b>	<b>21</b>	<b>22</b>	<b>31</b>	<b>19</b>	<b>17</b>	<b>11</b>	<b>14</b>	<b>10</b>	<b>-</b>

Table 4: Score and rank table for summer season computed over the MED-CORDEX domain.  
The value corresponds to the mean over the domain and their rank is indicated into bracket.  
Bold values indicate the best models for each one of the four evaluation aspect.

Model	ANALOG	CDFt-so	GAM	GAM-so	SWG	SWG-s	EURO-CNRM	EURO-IPSL	ERA-I
Wet days % bias	-0.75(3)	-0.10(1)	35.43(6)	-0.10(1)	-0.10(1)	0.14(2)	11.90(5)	3.98(4)	3.48
Wet mean persistence	-0.08(2)	-0.51(3)	10.26(6)	-0.51(3)	-0.51(3)	-0.70(4)	0.78(5)	-0.04(1)	0.23
Dry mean persistence	-18.44(3)	-9.70(2)	193.63(6)	-9.70(2)	-9.70(2)	5.06(1)	-18.45(4)	-18.60(5)	-10.74
Brier Score	0.30(4)	0.16(1)	0.40(6)	0.16(1)	0.16(1)	0.18(2)	0.31(5)	0.29(3)	0.14
<b>Total Rank Occurrence</b>	<b>12</b>	<b>7</b>	<b>24</b>	<b>7</b>	<b>7</b>	<b>9</b>	<b>19</b>	<b>13</b>	<b>-</b>
Mean bias mm	-0.31(3)	1.02(7)	-3.37(8)	-0.86(5)	0.13(2)	0.00(1)	-0.86(5)	0.54(4)	-1.31
Variance Ratio%	85.26(3)	138.18(5)	3.38(8)	30.59(6)	96.97(1)	82.57(4)	90.17(2)	183.01(7)	74.69
Q99 bias mm	-2.51(4)	3.49(6)	-20.39(8)	0.80(2)	-0.25(1)	-2.81(5)	-1.67(3)	5.98(7)	-4.00
<b>Total Rank Intensity</b>	<b>10</b>	<b>18</b>	<b>24</b>	<b>13</b>	<b>4</b>	<b>10</b>	<b>10</b>	<b>18</b>	<b>-</b>
EOF1	1	2	4	7	2	7	5	5	-
Spatial pattern correlation	0.24(6)	0.29(4)	0.32(3)	0.28(5)	0.20(7)	0.10(8)	0.37(1)	0.37(1)	0.53
<b>Total Rank Spatial</b>	<b>7</b>	<b>6</b>	<b>7</b>	<b>12</b>	<b>9</b>	<b>15</b>	<b>6</b>	<b>6</b>	<b>-</b>
Cor. Annual Amount	0.27(6)	0.50(1)	0.38(3)	0.32(5)	0.25(7)	-0.05(8)	0.42(2)	0.38(3)	0.72
Cor. Seas. Cycle	0.83(4)	0.85(2)	0.90(1)	0.80(5)	0.84(3)	0.59(8)	0.65(7)	0.69(6)	0.88
AR1 (E-OBS:0.38)	0.31(3)	0.14(5)	0.69(4)	0.12(6)	0.11(7)	-0.01(8)	0.44(2)	0.38(1)	0.50
<b>Total Rank Temporal</b>	<b>13</b>	<b>8</b>	<b>8</b>	<b>16</b>	<b>17</b>	<b>24</b>	<b>11</b>	<b>10</b>	<b>-</b>

Table 5: Score and rank table for summer season computed over the EURO-CORDEX domain.

The value corresponds to the mean over the domain and their rank is indicated into bracket.

Bold values indicate the best models for each one of the four evaluation aspect.

when driven by historical GCM fields would be assessed. The evaluation would be performed only in terms of statistics. In other words, indicators needing day-to-day synchronicity (e.g., Brier score and daily maps correlation) would not be relevant in that case. The next step would be to assess the capability of the SDMs to capture changes in future spatial and/or temporal local-scale properties. The couple “GCM/SDM” would be evaluated in a climate change context with a RCM-based pseudo-observations approach, for example as developed in Vrac et al. [2007a] and applied in Gaitan et al. [2014]. RCMs will be considered as proxies of future climate conditions and RCMs and SDMs have to be driven by the same GCM simulations. SDMs fitted to CTRL GCM simulations and pseudo-observations coming from RCM over the same time period will be driven with future GCM simulations (multiple emissions scenarios can be used) to generate new time series. Good agreement between those time series and the future RCM time series would mean that the SDM is able to capture a similar climate change signal as that simulated by the RCM.

A multi-model approach can also be an interesting follow-up study. It has been first tested in Sanders [1963] for subjective and Perrone & Miller

[1985] for objective weather forecasting and has proven itself to be superior to the methodologies applied individually. There are many occasions when this result is verified. Even theoretical contributions are made to support these experimental facts [e.g. Hagedorn et al., 2005]. However, it is not generalized until the 2000s [e.g., Palmer & Shukla, 2000; Pavan & Doblas-Reyes, 2000; Lambert & Boer, 2001; Gillett et al., 2003; Jacob et al., 2007; Ruti et al., 2011; Solman et al., 2013; Gallardo et al., 2013] and is consolidated as the standard in studies of climate performed with dynamical models. Therefore, future studies should include the multi-model approach when MED-CORDEX and EURO-CORDEX databases are completed. This methodology could be thus extended, as noted by Haylock et al. [2006] a mix of dynamical and statistical models. Note that one major difference between ensemble methods in weather forecasting and in climate studies is that the first must deal effectively with uncertainty in initial conditions, while in climate studies this uncertainty is not as much relevant.

Moreover, a way to refine the results would be to study the impacts of E-OBS uncertainties on the downscaled data. Some studies pointed out some quality inconsistencies. For instance in Hofstra et

al. [2009] problems such as data homogeneity over the E-OBS domain or oversmoothing in interpolation scheme causing difficulties to catch correctly the extremes or rain patterns over mountains have been pointed out. Therefore, the data uncertainty caused by the interpolation is ill-estimated. In this study, E-OBS V8 has been used. Potentially some improvements can be expected, if the last version E-OBS V11 is used instead, since the network density has been increased and an artefact of drizzle occurrence has been corrected. However, concerning the drizzle effect, it should not influence our results since the rain occurrence threshold is set at 1 mm. This occurrence threshold could also influence the results. In our case, simulations with a 0 mm threshold have also been tested for all the models (not shown). This changes the indicators values but does not influence the ranking of the models. The poor performance of GAM is not a consequence of the threshold since the same poor performances of GAM have also been observed for the 0 mm threshold. This mainly comes from the fact that the deterministic TF based models are not suited to simulate precipitation. Besides, concerning the drizzle effect of the RCMs, the results show that the tested RCMs produce too many rainy days even with this threshold except for MED-IPSL model (see FIGURE 3).

Improvements can also be made on SDMs calibration, for instance by improving the predictors selection process or adding other predictors. It is worth noticing that the first exploratory step based on the SPARSE CCA algorithm (i.e., to determine the variables that make sense as predictors for precipitation downscaling) has been performed only on the first principal component of each variable. Although the SPARSE CCA method is computationally intensive, it would be interesting to have additional leading PCs in this exploratory analysis to bring more robustness to the choice of the predictors. Moreover, as the SPARSE CCA has not been applied in the cross-validation context, the performance of the SDMs as assessed via cross-validation could be overly optimistic (or at least biased). Although the differences could be minor, it would be interesting to perform the selection of the predictors within the cross-validation procedure. Note that the cross-validation scheme used

in this study has a rather short calibration period (20 years), which may underestimate or even overestimate the skills for some methods. One solution could be to use a “29-leave-one-out” scheme, with calibrations of the models made on 29 years and evaluations on the left-out year. This 29-leave-one-out strategy, however, may not be an adapted strategy to evaluate the performances of the models in a changing climate context. Indeed, as the one-year left out would be either surrounded by the 29 calibration years, or appended (before or after) to the 29 calibration years, the basic statistical properties of the large-scale predictors and of the local-scale data should be the same in the 29 calibration years and the evaluation year. Hence, this strategy could provide overly optimistic results compared to an evaluation performed on a whole decade (or more). Besides, the 20-leave-10-out method is closer to the framework in which the downscaling methods are applied (calibration on historical period and application on future period). That is why, despite the limited length (20 years) of the calibration period, the “turning” 20 leave-10-out cross-validation procedure has been favoured in this study. Predictors relevant in terms of rain physical process such as the CAPE [convective available potential energy, Foufoula-Georgiou & Tsonis, 1996], the vertical wind shear [Wingo & Cecil, 2009] or moisture flux [Yang et al., 2010] characterizing the atmosphere instability can be also considered. Some temporal information could be added by including the previous day precipitation observation especially for the occurrence model [Kleiber et al., 2012]. Weather regimes or seasonal cycle indicators could also bring interesting information leading to potential improvements. Globally, the intercomparison could be broadened by adding more statistical and dynamical models or adding new variables of interest such as temperature or wind. Thus, an inter-variable analysis could be carried out based on adapted indicators.

Besides, the SDMs’ features can be improved. According to the results, it would be legitimate to focus on the ANALOG model. However, this model presents some limitations. Indeed, it is limited by its range over the calibration period: in case of future projections in context of climate change signal it is possible to miss that signal be-



cause ANALOG cannot go beyond the calibration climate range. Besides, this model has more large-scale information than the other models tested here. This could also explain its performance. One can object that the ANALOG model could have been run with the same set of predictors that have been used for the other SDMs (i.e., the 12 PCs). The authors are not aware of any application of the ANALOG model with PCs as predictors. The usual way to apply it is to work with fields of anomalies. However, the ANALOG model has also been run with PCs as predictors for comparison. This approach strongly degrades the results of the ANALOG model compared to using the anomalies as predictors. This model presents large biases and sometimes the results are even unrealistic (not shown). Some analog approaches combine multiple analogs [e.g., Radanovics et al., 2013; Chardon et al., 2014; Yiou, 2014]. In the way the analogs are computed in our study, the use of a combination (e.g., through a mean or weighted average) of multiple analogs would decrease the quality of the ANALOG simulation. Indeed, it would undermine the mean and the variance of the ANALOG model output and could also introduce a bias in the wet days frequency. An artificial variance-inflating procedure would then be necessary to maintain the main statistical properties.

On the opposite, a focus can be given to the SWG model. Indeed, in spite of its caveats in terms of spatiality and temporality, it seems to be very promising. There are many ways of improvement for instance by giving the model a spatial structure through a covariance function [e.g., Vischel et al., 2009] or by improving the Bernoulli/Gamma marginal probability distribution function used here. It would allow us to generate daily rain fields with a spatial coherence and one

model for an entire region instead of a model per grid-point. Instead of two seasons, considering weather regimes could also lead to a potential improvement [Vrac et al., 2007d]. Of course, the CORDEX regions are probably too large to define a simple but realistic dependence model. However, improving the SWG model seems a good compromise between the many leads of improvements and the model flexibility. Spatial coherence can also be ensured in other modelling framework: for instance the spatial MOS model, EC-BC, developed in Vrac & Friederichs [2015]. Another path can be a combination of a stochastic model with an ANALOG model.

Finally, the present study has focused entirely on the intercomparison framework and the results that have come out of it. This work aspires to set an easily reproducible ground rules to conduct a RCM intercomparison which includes RCMs as well as SDMs and allows the SDMs to fit into the CORDEX initiative. Based on that, it is expected to perform consistent future intercomparison studies between SDMs as well as RCMs.

**Acknowledgments** The authors are thankful to all the RCM data providers, especially to R. Vautard (IPSL) and A. Collette (INERIS) for the WRF-IPSL-INERIS44 EURO-CORDEX run and Météo-France/CNRM (A. Alias, S. Somot) for the CNRM-ALADIN52 MED-CORDEX run. The MED-CORDEX simulations used in this work are downloaded from the MED-CORDEX data portal ([www.medcordex.eu/medcordex.php](http://www.medcordex.eu/medcordex.php)). This work has been partially funded by the Spanish Ministry of Education and Science and the European Regional Development Fund, through Grant CGL2007-66440-C04-02. We also thank F. Blondot (HSM) who, in collaboration with Julie Carreau, helped us for the predictors selection. All the estimations and simulations for the stochastic and the TF models have been done with the R-package “VGAM” [Yee, 2010]. Special thanks are due to Thomas Yee, the “VGAM” package author for his help. The MOS model has been computed thanks to the R-package CDFt [Michelangeli et al., 2009]. This work has been supported by the ANR StaRMIP project, the ANR REMEMBER project and the REMedHE GICC project. It is a contribution to the HyMeX program (Hydrological cycle in The Mediterranean Experiment) through INSU-MISTRALS support and the MED-CORDEX program. It was supported by the IPSL group for regional climate and environmental studies, with granted access to the HPC resources of IDRIS (under allocation i2011010227). It is a contribution to the CORDEX-ESD initiative (<http://wcrp-cordex.ipsl.jussieu.fr/index.php/community/cordex-esd>) and to the COST Action VALUE [<http://www.value-cost.eu/>, Maraun et al., 2015].

### 3. Étude complémentaire concernant le choix du seuil

Une question importante qui a été évoquée dans l'article, (à laquelle nous ne répondons pas, mais qui sera plutôt discutée et illustrée ici) est la question du choix du seuil d'occurrence des précipitations. En effet, ce seuil a été fixé à 1 mm dans l'article, ce qui nous a imposé certaines contraintes techniques pour les modèles statistiques en particulier pour les modèles CDFt-so, SWG et SWG-s (*cf.* section 3.1 de l'article). Ce choix est souvent fait à cause du manque de fiabilité des valeurs faibles dans les observations et dans les RCMs. Pour les observations, ce manque de fiabilité vient de l'incertitude des instruments ou de l'interpolation utilisée (ce qui est le cas de E-OBS). Les SDMs étant grandement influencés par la qualité des observations, un seuil est imposé afin d'éviter l'influence de données trop incertaines. Pour les RCMs, l'“effet crachin” (ou *drizzle effect* en anglais) génère beaucoup de quantités très faibles ( $\sim 10^{-5}$  mm/jour).

Néanmoins, tous les modèles comparés sont entre autres choses destinés à des utilisateurs pour servir d'entrée notamment à des modèles d'impacts par exemple hydrologiques, écologiques ou d'agricultures. Du point de vue de l'utilisateur, le choix de ce seuil pourrait avoir des conséquences non-négligeables. Pour illustrer cela, les SDMs ont été recalibrés et de nouvelles simulations ont été réalisées avec un seuil d'occurrence de 0 mm. Nous allons axer la discussion sur un seul critère qui illustre très bien cette question qui semble importante du point de vue de la modélisation d'impacts : la variabilité interannuelle.

La FIGURE II.15 représente le cumul annuel des précipitations comprises entre 0 et 1 mm pour chaque modèle. On peut constater que les SDMs ont un cumul du même ordre de grandeur que celui des observations excepté GAM dont le cumul est environ quatre fois plus fort. Ceci est cohérent avec ce qui a été constaté dans l'article ; à savoir que GAM produit trop de jours de pluie avec de faibles cumuls journaliers. La même chose est constatée pour ERA-I. Les RCMs de leur côté présentent tous des cumuls deux fois plus élevés. Il y a au moins une raison à cela : “l'effet crachin” des RCMs qui produit beaucoup de jours avec de très petits cumuls ce qui confirme le fort biais positif en fréquence observé dans l'article.

Dans tous les cas, les cumuls des précipitations faibles entre 0 et 1 mm par jour représentent des quantités non-négligeables, ce qui peut potentiellement influencer les modèles d'impacts. Du point de vue de l'utilisateur, il est important d'être conscient de ce fait pour choisir avec soin les simulations en entrées. Une solution pourrait être de choisir en tant que seuil la plus petite valeur non-nulle du jeu d'observation de référence qui est supposé être de bonne qualité, même si cela ne répond pas à la question d'une méthode pour un choix objectif de ce seuil.





FIGURE II.15 – Cumuls annuels des précipitations comprises entre 0 et 1 mm en  $\text{mm}\cdot\text{year}^{-1}$ . *En haut* on retrouve tous les SDMs, ERA-I et E-OBS, *en bas* tous les RCMs et E-OBS à Montpellier.

## Cumulated rain amount above 1mm difference in Montpellier




FIGURE II.16 – Différence entre les cumuls annuels des précipitations au-delà de 1 mm entre les SDMs calibrés avec le seuil à 0 mm et 1 mm (en  $\text{mm}\cdot\text{year}^{-1}$ ). On retrouve tous les SDMs, ERA-I et E-OBS à Montpellier. La courbe de E-OBS est cachée par celle d'ANALOG.

Le choix du seuil pose également une question du point de vue des modèles statistiques eux-mêmes. Le seuil influence la calibration des modèles : la régression logistique pour l'occurrence et la modélisation de l'intensité des modèles GAM-so, SWG et SWG-s. La FIGURE II.16 illustre cela. La différence entre les cumuls annuels des précipitations au-delà de 1 mm entre les SDMs calibrés avec le seuil à 0 mm et 1 mm sont tracés (" $\text{simu}_{0\text{mm}} - \text{simu}_{1\text{mm}}$ "). Les modèles ANALOG et GAM ne présentent aucune différence puisque ces modèles sont seuillés au niveau souhaité et sont donc identiques au-dessus de 1mm (de même que E-OBS). CDFt-so présente des différences positives uniquement assez importantes (jusque 450 mm par an) issues de la calibration de la régression logistique. Dans le cas où l'on calibre à 0 mm, les simulations génèrent plus de jours de pluie et donc des cumuls annuels plus importants que dans le cas de la calibration à 1 mm. Dans le cas de GAM-so, SWG et SWG-s les différences sont positives et négatives avec des variations plus importantes pour les modèles stochastiques ( $\sim 300$  mm). Il est difficile d'attribuer cette différence à l'occurrence ou à l'intensité. Avec le seuil à 0 mm on observe plus de jours de pluie et donc a priori un cumul annuel plus important mais ce n'est pas toujours le cas. Dans le cas de GAM-so, l'intensité est calibrée en excluant les valeurs en dessous du seuil ce qui évidemment donne des intensités différentes selon le seuil. Pour les modèles stochastiques, la calibration de l'intensité est identique. C'est le tirage fait conditionnellement au seuil lors de la simulation qui influence l'intensité des précipitations et cause les différences pour SWG et SWG-s. La calibration aurait pu être faite avec un seuil à 1mm, néanmoins cela pose un problème théorique. En effet, l'hypothèse d'une distribution gamma n'est plus valide pour l'intensité des précipitations si on exclue les valeurs entre 0 et 1 mm. De plus, cela augmente artificiellement la variance. La FIGURE II.17 représente le rapport entre la variance journalière estimée

à Montpellier pour une calibration à 1 mm et à 0 mm. Le rapport des variances est majoritairement supérieur à 1.




FIGURE II.17 – Rapport des variances journalières estimées à Montpellier pour une calibration à 1 mm et à 0 mm.

Ces quelques illustrations mettent en relief l'importance du choix de ce seuil. Actuellement, ce seuil est souvent choisi en fonction des données utilisées et de l'étude concernée. Cela reste une question de recherche à part entière. Il existe des pistes de recherches se focalisant sur une façon de modéliser occurrence et intensité de façon simultanée. STEHLÍK & BÁRDOSSY [2002] ; VISCHEL et al. [2009] ont suggéré une transformation de la distribution des précipitations en une gaussienne où les valeurs transformées négatives correspondent aux jours secs. BAXEVANI & LENNARTSSON [2015] ont employé un gaussienne tronquée à 0 à cette même fin.

## 4. Perspectives

Les travaux développés dans ce chapitre amènent plusieurs perspectives. Nous allons aborder certaines des perspectives évoquées dans la section 5.2 de l'article et d'autres qui n'y sont pas et qui seront traitées (en partie tout au moins) dans la suite de ce manuscrit.

Le choix d'un modèle de régionalisation ne peut pas se faire uniquement sur la capacité des modèles à reproduire la climatologie de E-OBS à partir de ERA-I. En effet, l'évaluation d'un modèle doit également prendre en compte son comportement dans un contexte de climat futur et donc de changement climatique. L'intercomparaison menée dans ce chapitre se situe uniquement dans le contexte "hindcast" de CORDEX. Ceci a permis d'évaluer les modèles, autrement dit de vérifier leur robustesse en climat actuel. Ainsi, nous sommes en mesure de passer à l'étape suivante et de tester le comportement des modèles forcés par les GCMs. Dans le cas des SDMs, ceci commence par une calibration sur 1979-2005 à partir de ERA-I et de E-OBS. C'est le point de départ permettant d'évaluer le comportement des GCMs en tant que prédicteurs. Ce sera l'objet du CHAPITRE III où la sensibilité des SDMs aux GCMs sera évaluée. Le couple "GCM/SDM" doit être, dans un premier temps évalué sur la période dite historique (ou CTRL). À partir des calibrations, des simulations forcées par ERA-I et par un ou plusieurs GCMs seront comparées aux observations. Ainsi, nous pourrions évaluer si les GCMs fournissent de bons prédicteurs ou si au contraire ils induisent des biais importants dans les simulations. Nous en profiterons pour mettre en place et tester une procédure de correction des biais dans les prédicteurs issus des GCMs sur la période CTRL. Nous étendrons ensuite cela dans un contexte de changement climatique avec plusieurs forçages climatiques. Ce sera également l'objet du CHAPITRE III : nous testerons plusieurs couples "GCM/SDM" afin d'évaluer la sensibilité des SDMs aux GCMs et à la procédure de correction des biais dans les GCMs dans un contexte de climat futur.

L'amélioration des SDMs est une autre continuation possible de ce chapitre. En se basant sur les résultats de l'article, il serait intéressant d'améliorer le modèle ANALOG. En effet, malgré l'absence d'une discrimination claire entre les modèles, on observe un très bon comportement de ce modèle pour l'ensemble de quatre aspects des précipitations considérés (à savoir occurrence, intensité, propriétés spatiale et temporelles, *cf.* TABLEAUX 4 et 5 de l'article). Cependant, il présente quelques limitations. En effet, il est limité par sa calibration : dans un contexte de projections futures, le modèle manquera très probablement le signal du changement climatique puisque ANALOG ne peut générer des valeurs au-delà de ses bornes de calibrations. De plus, dans notre étude, nous avons fourni beaucoup plus d'informations à grande échelle à ce modèle qu'aux autres, à savoir l'ensemble des champs d'anomalies des prédicteurs (au lieu des deux premières PCs) : ceci pourrait expliquer son bon comportement. Certaines études combinent plusieurs analogues de circulations [e.g., RADANOVICS et al., 2013; CHARDON et al., 2014; YIOU, 2014]. L'utilisation d'une combinaison (e.g., à l'aide d'une moyenne pondérée) de plusieurs analogues dégraderait la qualité de la simulation ANALOG. Cela atténuerait la moyenne et la variance des sorties du modèle ANALOG et potentiellement induirait un biais dans la fréquence de jour de pluie. Une procédure artificielle d'inflation de la variance [HUTH, 1999] serait nécessaire afin de maintenir les principales propriétés statistiques.

Nous allons donc plutôt nous concentrer au CHAPITRE IV sur un modèle de type stochastique (SWG). Bien que SWG présente des lacunes en termes de caractéristiques spatiales et temporelles, il semble néanmoins assez prometteur. En effet, ce modèle offre de très nombreuses voies d'améliorations. En se plaçant dans le cadre de processus spatiaux, nous pourrions contraindre spatialement SWG par une fonction de covariance spatiale [e.g., BOUVIER et al., 2003 ; VISCHEL et al., 2009 ]. Les propriétés non-stationnaires (et donc intéressantes dans un contexte de changement climatique) de la loi de probabilité marginale Bernoulli/Gamma que nous avons utilisée pour SWG seront conservées (la loi marginale pourra également faire l'objet d'améliorations). Ceci nous permettra de générer des champs de précipitations spatialement cohérents sur une région entière au lieu d'un modèle par station ou point de grille. Ceci fera l'objet du CHAPITRE IV où un modèle spatial de réduction d'échelle sera développé. Les régions CORDEX sont très probablement trop étendues pour modéliser une dépendance spatiale réaliste avec un seul modèle statistique. Nous nous placerons sur une région plus restreinte. Une autre amélioration consisterait à remplacer la séparation en deux saisons par des régimes de temps [VRAC et al., 2007d]. La séparation en deux grandes saisons comme nous l'avons fait dans ce chapitre peut amener les modèles stochastiques à "lisser" les précipitations. En effet, lors de l'apprentissage, l'optimisation des paramètres se fait avec des conditions à grande échelle très différentes. Ceci peut amener le modèle à manquer des événements exceptionnels tels que des orages avec de fortes précipitations. Pour cette raison, une calibration mensuelle sera adoptée au CHAPITRE IV. L'inconvénient de cela est l'optimisation d'un très grand nombre de paramètres. Une alternative, pourrait être de regrouper les jours en fonction de régimes saisonniers. Nous tenterons de donner une définition de régimes saisonniers de circulation au CHAPITRE V. Ceci amènera plusieurs perspectives futures. Par exemple, on pourra combiner ce genre d'approche, en définissant des régimes saisonniers de précipitations, au modèle spatial mais cela ne fera pas l'objet de ce manuscrit. Il existe également d'autres façons d'assurer la cohérence spatiale dans d'autres cadres de modélisation : par exemple le modèle MOS spatial et multivarié, EC-BC, développé dans VRAC & FRIEDERICHS [2015]. Une autre piste serait de combiner un modèle stochastique avec un modèle d'analogues de circulation.

Privilégier l'amélioration du modèle SWG semble être un bon compromis entre les différentes possibilités de développement et la flexibilité des modèles stochastiques.

## 5. Synthèse des résultats

Une intercomparaison de plusieurs modèles de réduction d'échelle a été menée dans ce chapitre. A cette fin, le cadre de travail suivant un certain cahier des charges a été mis en place :

- i. tous les modèles ont des prédicteurs communs (autant que possible), venant de la même base de données : les réanalyses ERA-I;
- ii. les observations et les modèles ont la même résolution, sur un domaine commun. La résolution choisie est de  $0.44^\circ$  étant donné la résolution des RCMs et du jeu de données d'observations (E-OBS) disponibles;
- iii. au moins un représentant de chaque familles de SDMs ainsi que RCMs doivent faire partie du panel de modèles.

Ainsi 11 modèles (six SDMs et cinq RCMs) de précipitations ont été sélectionnés et comparés d'un point de vue climatologique selon des indicateurs caractérisant les quatre aspects des précipitations suivants : occurrence, intensité ainsi que les propriétés spatiales et temporelles. Ce chapitre a permis de construire et de tester la robustesse d'un protocole d'intercomparaison de modèles de réductions d'échelle aussi bien statistiques que dynamiques. Des modèles très différents du point de vu conceptuel ont pu être comparés.

Les principaux résultats montrent qu'aucun modèle n'est clairement supérieur aux autres. Les résultats dépendent quasi-entièrement des indicateurs choisis et *a fortiori* du domaine scientifique considéré et des besoins de l'utilisateur.

Ce travail aspire à mettre en place un cadre de travail aisément reproductible permettant de mener des travaux d'intercomparaison pouvant s'inscrire dans une initiative comme CORDEX en incluant aussi bien RCMs que SDMs.



## Références Bibliographiques du Chapitre II

- AMBROSINO, Chiara, CHANDLER, Richard E. & TODD, Martin C. [2014]. "Rainfall-derived growing season characteristics for agricultural impact assessments in South Africa". *Theoretical and Applied Climatology*. Vol. 115. no. 3-4, p. 411–426.
- BARDOSSY, Andras & PLATE, Erich J. [1992]. "Space-time model for daily rainfall using atmospheric circulation patterns". *Water Resources Research*. Vol. 28. no. 5, p. 1247–1259.
- BARNSTON, Anthony G. & LIVEZEY, Robert E. [1987]. "Classification, Seasonality and Persistence of Low-Frequency Atmospheric Circulation Patterns". *Monthly Weather Review*. Vol. 115. no. 6, p. 1083–1126.
- BAXEVANI, Anastassia & LENNARTSSON, Jan [2015]. "A spatiotemporal precipitation generator based on a censored latent Gaussian field". *Water Resources Research*. Vol. 51. no. 6, p. 4338–4358.
- BELLONE, Enrica, HUGHES, James P. & GUTTORP, Peter [2000]. "A hidden Markov model for downscaling synoptic atmospheric patterns to precipitation amounts". *Journal of Hydrology*. Vol. 15. no. 1, p. 1–12.
- BOUGEAULT, Philippe [1985]. "A Simple Parameterization of the Large-Scale Effects of Cumulus Convection". *Monthly Weather Review*. Vol. 113. no. 12, p. 2108–2121.
- BOUVIER, Christophe, CISNEROS, Leonardo, DOMINGUEZ, Ramon, LABORDE, Jean-Pierre & LEBEL, Thierry [2003]. "Generating rainfall fields using principal components (PC) decomposition of the covariance matrix : a case study in Mexico City". *Journal of Hydrology*. Vol. 278. no. 1–4, p. 107–120.
- BRIER, Glenn W. [1950]. "Verification of forecasts expressed in terms of probability". *Monthly Weather Review*. Vol. 78. no. 1, p. 1–3.
- BUISHAND, T. A., SHABALOVA, M. V. & BRANDSMA, T. [2004]. "On the Choice of the Temporal Aggregation Level for Statistical Downscaling of Precipitation". *Journal of Climate*. Vol. 17. no. 9, p. 1816–1827.
- BÜRGER, G., MURDOCK, T. Q., WERNER, A. T., SOBIE, S. R. & CANNON, A. J. [2012b]. "Downscaling Extremes-An Intercomparison of Multiple Statistical Methods for Present Climate". *Journal of Climate*. Vol. 25. no. 12.
- CAVAZOS, Tereza & HEWITSON Bruce, C. [2005]. "Performance of NCEP-NCAR reanalysis variables in statistical downscaling of daily precipitation". *Climate Research*. Vol. 28. no. 2, p. 95–107.
- CHABOUREAU, Jean-Pierre & BECHTOLD, Peter [2002]. "A Simple Cloud Parameterization Derived from Cloud Resolving Model Data : Diagnostic and Prognostic Applications". *Journal of the Atmospheric Sciences*. Vol. 59. no. 15, p. 2362–2372.
- CHABOUREAU, Jean-Pierre & BECHTOLD, Peter [2005]. "Statistical representation of clouds in a regional model and the impact on the diurnal cycle of convection during Tropical Convection, Cirrus and Nitrogen Oxides (TROCCINOX)". *Journal of Geophysical Research : Atmospheres*. Vol. 110. no. D17.
- CHANDLER, R. E. & WHEATER, H. S. [2002]. "Analysis of rainfall variability using generalized linear models : A case study from the west of Ireland". *Water Resour. Res.* Vol. 38(10), p. 1192.
- CHARDON, J., HINGRAY, B., FAVRE, A., AUTIN, P., GAILHARD, J., ZIN, I. & OBLED, C. [2014]. "Spatial Similarity and Transferability of Analog Dates for Precipitation Downscaling over France". *Journal of Climate*. Vol. 27. no. 13, p. 5056–5074.
- CHARLES, Stephen P., BATES, Bryson C., WHETTON, Peter H. & HUGHES, James P. [1999]. "Validation of downscaling models for changed climate conditions : case study of southwestern Australia". *Climate Research*. Vol. 12. no. 1, p. 1–14.
- CHIRIACO, Marjolaine, BASTIN, Sophie, YIOU, Pascal, HAEFFELIN, Martial, DUPONT, Jean-Charles & STÉFANON, Marc [2014]. "European heatwave in July 2006 : Observations and modeling showing how local processes amplify conducive large-scale conditions". *Geophysical Research Letters*. Vol. 41. no. 15, p. 5644–5652.
- CHRISTENSEN, Jens Hesselbjerg & CHRISTENSEN, Ole Bøssing [2007]. "A summary of the PRUDENCE model projections of changes in European climate by the end of this century". *Climatic Change*. Vol. 81. no. 1, p. 7–30.
- COIFFIER, Jean [2011]. "Fundamentals of Numerical Weather Prediction". Cambridge Books Online. Cambridge University Press.
- COLIN, Jeanne, DÉQUÉ, Michel, RADU, Raluca & SOMOT, Samuel [2010]. "Sensitivity study of heavy precipitation in Limited Area Model climate simulations : influence of the size of the domain and the use of the spectral nudging technique". *Tellus A*. Vol. 62. no. 5, p. 591–604.
- CRAWFORD, Thomas, L. BETTS, Nicholas & FAVIS-MORTLOCK, David [2007]. "GCM grid-box choice and predictor selection associated with statistical downscaling of daily precipitation over Northern Ireland". *Climate Research*. Vol. 34. no. 2, p. 145–160.
- CUXART, J., BOUGEAULT, P. & REDELSPERGER, J.-L. [2000]. "A turbulence scheme allowing for mesoscale and large-eddy simulations". *Quarterly Journal of the Royal Meteorological Society*. Vol. 126. no. 562, p. 1–30.
- DEE, D. P., UPPALA, S. M., SIMMONS, A. J., BERRISFORD, P., POLI, P., KOBAYASHI, S., ANDRAE, U., BALMASEDA, M. A., BALSAMO, G., BAUER, P., BECHTOLD, P., BELJAARS, A. C. M., BERG, L. van de,

- BIDLOT, J., BORMANN, N., DELSOL, C., DRAGANI, R., FUENTES, M., GEER, A. J., HAIMBERGER, L., HEALY, S. B., HERSBACH, H., HÓLM, E. V., ISAKSEN, I., KÄLLBERG, P., KÖHLER, M., MATRICARDI, M., McNALLY, A. P., MONGE-SANZ, B. M., MORCRETTE, J.-J., PARK, B.-K., PEUBEY, C., ROSNAY, P. de, TAVOLATO, C., THÉPAUT, J.-N. & VITART, F. [2011]. “The ERA-Interim reanalysis : configuration and performance of the data assimilation system”. *Quarterly Journal of the Royal Meteorological Society*. Vol. 137. no. 656, p. 553–597.
- DENIS, B., LAPRISE, R. & CAYA, D. [2003]. “Sensitivity of a regional climate model to the resolution of the lateral boundary conditions”. *Climate Dynamics*. Vol. 20. no. 2-3, p. 107–126.
- DIBIKE, Yonas B. & COULIBALY, Paulin [2006]. “Temporal neural networks for downscaling climate variability and extremes”. *Neural Networks*. Vol. 19. no. 2. Earth Sciences and Environmental Applications of Computational Intelligence, p. 135–144.
- DOMÍNGUEZ, M., ROMERA, R., SÁNCHEZ, E., FITA, L., FERNÁNDEZ, J., JIMÉNEZ-GUERRERO, P., MONTÁVEZ, JP, CABOS, WD, LIGUORI, G & GAERTNER, MÁ [2013]. “Present-climate precipitation and temperature extremes over Spain from a set of high resolution RCMs”. *Climate Research*. Vol. 58. no. 2, p. 149–164.
- DOUVILLE, H., PLANTON, S., ROYER, JF., STEPHENSON, DB., TYTECA, S., KERGOAT, L., LAFONT, S. & BETTS, RA [2000]. “The importance of vegetation feedbacks in doubled-CO2 time-slice experiments.” *Annales Geophysicae*. Vol. 11. no. 12, p. 1095–1115.
- DROBINSKI, P., DUCROCQ, V., ALPERT, P., ANAGNOSTOU, E., BÉRANGER, K., BORGA, M., BRAUD, I., CHANZY, A., DAVOLIO, S., DELRIEU, G., ESTOURNEL, C., BOUBRAHMI, N. Filali, FONT, J., GRUBIŠIĆ, V., GUALDI, S., HOMAR, V., IVANČAN-PICEK, B., KOTTMEIER, C., KOTRONI, V., LAGOUVARDO, K., LIONELLO, P., LLASAT, M. C., LUDWIG, W., LUTOFF, C., MARIOTTI, A., RICHARD, E., ROMERO, R., ROTUNNO, R., ROUSSOT, O., RUIN, I., SOMOT, S., TAUPIER-LETAGE, I., TINTORE, J., UIJLENHOET, R. & WERNLI, H. [2014]. “HyMeX : A 10-Year Multidisciplinary Program on the Mediterranean Water Cycle”. *Bulletin of the American Meteorological Society*. Vol. 95. no. 7, p. 1063–1082.
- DÉQUÉ, M. & PIEDELIEVRE, J.Ph. [1995]. “High resolution climate simulation over Europe”. *Climate Dynamics*. Vol. 11. no. 6, p. 321–339.
- DÉQUÉ, Michel [2007]. “Frequency of precipitation and temperature extremes over France in an anthropogenic scenario : Model results and statistical correction according to observed values”. *Global and Planetary Change*. Vol. 57. no. 1–2, p. 16–26.
- ECMWF [2004]. “IFS documentation CY28r1. ECMWF, Reading”. [http://old.ecmwf.int/research/ifs-docs/CY28r1/pdf\\_files/Physics.pdf](http://old.ecmwf.int/research/ifs-docs/CY28r1/pdf_files/Physics.pdf). P. 7–32.
- EK, M. B., MITCHELL, K. E., LIN, Y., ROGERS, E., GRUNMANN, P., KOREN, V., GAYNO, G. & TARPLEY, J. D. [2003]. “Implementation of Noah land surface model advances in the National Centers for Environmental Prediction operational mesoscale Eta model”. *Journal of Geophysical Research : Atmospheres*. Vol. 108. no. D22.
- FEALY, Rowan & SWEENEY, John [2007]. “Statistical downscaling of precipitation for a selection of sites in Ireland employing a generalised linear modelling approach”. *International Journal of Climatology*. Vol. 27. no. 15, p. 2083–2094.
- FLAOUNAS, Emmanouil, BASTIN, Sophie & JANICOT, Serge [2011]. “Regional climate modelling of the 2006 West African monsoon : sensitivity to convection and planetary boundary layer parameterisation using WRF”. *Climate Dynamics*. Vol. 36. no. 5-6, p. 1083–1105.
- FLAOUNAS, Emmanouil, DROBINSKI, Philippe & BASTIN, Sophie [2013]. “Dynamical downscaling of IPSL-CM5 CMIP5 historical simulations over the Mediterranean : benefits on the representation of regional surface winds and cyclogenesis”. *Climate Dynamics*. Vol. 40. no. 9-10, p. 2497–2513.
- FOUFOULA-GEORGIOU, Efi & TSONIS, Anastasios [1996]. “Preface [to the special section on Space-Time Variability and Dynamics of Rainfall]”. *Journal of Geophysical Research : Atmospheres*. Vol. 101. no. D21, p. 26161–26163.
- FU, Congbin, WANG, Shuyu, XIONG, Zhe, GUTOWSKI, William J., LEE, Dong-Kyou, MCGREGOR, John L., SATO, Yasuo, KATO, Hisashi, KIM, Jeong-Woo & SUH, Myoung-Seok [2005]. “Regional Climate Model Intercomparison Project for Asia”. *Bulletin of the American Meteorological Society*. Vol. 86. no. 2, p. 257–266.
- GAITAN, CarlosF., HSIEH, WilliamW. & CANNON, AlexJ. [2014]. “Comparison of statistically downscaled precipitation in terms of future climate indices and daily variability for southern Ontario and Quebec, Canada”. *Climate Dynamics*. P. 1–17.
- GALLARDO, Clemente, GIL, Victoria, HAGEL, Edit, TEJEDA, César & CASTRO, Manuel de [2013]. “Assessment of climate change in Europe from an ensemble of regional climate models by the use of Köppen–Trewartha classification”. *International Journal of Climatology*. Vol. 33. no. 9, p. 2157–2166.
- GILLET, Nathan P., ZWIERS, Francis W., WEAVER, Andrew J. & STOTT, Peter A. [2003]. “Detection of human influence on sea-level pressure”. *Nature*. Vol. 422. no. 6929, p. 292–294.

- GIORGI, F., JONES, C. & ASRAR, G. R. [2009]. “Addressing climate information needs at the regional level : the CORDEX framework.” *Bulletin of the World Meteorologic Organization*. Vol. 58(3), p. 175–183.
- GRELL, Georg A. & DÉVÉNYI, Dezső [2002]. “A generalized approach to parameterizing convection combining ensemble and data assimilation techniques”. *Geophysical Research Letters*. Vol. 29. no. 14, p. 38–1–38–4.
- GRENIER, Patrick, PARENT, Annie-Claude, HUARD, David, ANCTIL, François & CHAUMONT, Diane [2013]. “An Assessment of Six Dissimilarity Metrics for Climate Analogs”. *Journal of Applied Meteorology and Climatology*. Vol. 52. no. 4, p. 733–752.
- GUDMUNDSSON, L., BREMNES, J. B., HAUGEN, J. E. & ENGEN-SKAUGEN, T. [2012]. “Technical Note : Downscaling RCM precipitation to the station scale using statistical transformations - a comparison of methods”. *Hydrology and Earth System Sciences*. Vol. 16. no. 9, p. 3383–3390.
- HAGEDORN, Renate, DOBLAS-REYES, Francisco J. & PALMER, T. N. [2005]. “The rationale behind the success of multi-model ensembles in seasonal forecasting – I. Basic concept”. *Tellus A*. Vol. 57. no. 3, p. 219–233.
- HARPHAM, Colin & WILBY, Robert L. [2005]. “Multi-site downscaling of heavy daily precipitation occurrence and amounts”. *Journal of Hydrology*. Vol. 312. no. 1–4, p. 235–255.
- HASTIE, T. & TIBSHIRANI, R. [1990]. “Generalized Additive Models”. Monographs on statistics and applied probability. Chapman & Hall.
- HAYLOCK, M. R., HOFSTRA, N., KLEIN TANK, A. M. G., KLOK, E. J., JONES, P. D. & NEW, M. [2008]. “A European daily high-resolution gridded data set of surface temperature and precipitation for 1950–2006”. *Journal of Geophysical Research : Atmospheres*. Vol. 113. no. D20.
- HAYLOCK, Malcolm R., CAWLEY, Gavin C., HARPHAM, Colin, WILBY, Rob L. & GOODESS, Clare M. [2006]. “Downscaling heavy precipitation over the United Kingdom : a comparison of dynamical and statistical methods and their future scenarios”. *International Journal of Climatology*. Vol. 26. no. 10, p. 1397–1415.
- HERRMANN, M., SOMOT, S., CALMANTI, S., DUBOIS, C. & SEVAULT, F. [2011]. “Representation of spatial and temporal variability of daily wind speed and of intense wind events over the Mediterranean Sea using dynamical downscaling : impact of the regional climate model configuration”. *Natural Hazards and Earth System Science*. Vol. 11. no. 7, p. 1983–2001.
- HEWITSON, BC & CRANE, RG [1996]. “Climate downscaling : techniques and application”. *Climate Research*. Vol. 7. no. 2, p. 85–95.
- HEWITT, Chris D. [2004]. “Ensembles-based predictions of climate changes and their impacts”. *Eos, Transactions American Geophysical Union*. Vol. 85. no. 52, p. 566.
- HOFSTRA, Nynke, HAYLOCK, Malcolm, NEW, Mark & JONES, Phil D. [2009]. “Testing E-OBS European high-resolution gridded data set of daily precipitation and surface temperature”. *Journal of Geophysical Research : Atmospheres*. Vol. 114. no. D21.
- HONG, S.-Y. & LIM, J.-O. J. [2006]. “The WRF single-moment 6-class microphysics scheme (WSM6)”. *Journal of the Korean Meteorological Society*. Vol. 42. no. 2, p. 129–151.
- HONG, Song-You, DUDHIA, Jimmy & CHEN, Shu-Hua [2004]. “A Revised Approach to Ice Microphysical Processes for the Bulk Parameterization of Clouds and Precipitation”. *Monthly Weather Review*. Vol. 132. no. 1, p. 103–120.
- HONG, Song-You, NOH, Yign & DUDHIA, Jimmy [2006]. “A New Vertical Diffusion Package with an Explicit Treatment of Entrainment Processes”. *Monthly Weather Review*. Vol. 134. no. 9, p. 2318–2341.
- HOUDIN, Frédéric, MUSAT, Ionela, BONY, Sandrine, BRACONNOT, Pascale, CODRON, Francis, DUFRESNE, Jean-Louis, FAIRHEAD, Laurent, FILIBERTI, Marie-Angèle, FRIEDLINGSTEIN, Pierre, GRANDPEIX, Jean-Yves, KRINNER, Gerhard, LEVAN, Phu, LI, Zhao-Xin & LOTT, François [2006]. “The LMDZ4 general circulation model : climate performance and sensitivity to parametrized physics with emphasis on tropical convection”. *Climate Dynamics*. Vol. 27. no. 7-8, p. 787–813.
- HUTH, Radan [1999]. “Statistical downscaling in central Europe : evaluation of methods and potential predictors”. *Climate Research*. Vol. 13. no. 2, p. 91–101.
- IACONO, Michael J., DELAMERE, Jennifer S., MLAWER, Eli J., SHEPHARD, Mark W., CLOUGH, Shepard A. & COLLINS, William D. [2008]. “Radiative forcing by long-lived greenhouse gases : Calculations with the AER radiative transfer models”. *Journal of Geophysical Research : Atmospheres*. Vol. 113. no. D13.
- JACOB, Daniela, BÄRRING, Lars, CHRISTENSEN, OleBøssing, CHRISTENSEN, JensHesselbjerg, CASTRO, Manuel de, DÉQUÉ, Michel, GIORGI, Filippo, HAGEMANN, Stefan, HIRSCHI, Martin, JONES, Richard, KJELLSTRÖM, Erik, LENDERINK, Geert, ROCKEL, Burkhardt, SÁNCHEZ, Enrique, SCHÄR, Christoph, SENEVIRATNE, SoniaI., SOMOT, Samuel, ULDEN, Aad van & HURK, Bart van den [2007]. “An inter-comparison of regional climate models for Europe : model performance in present-day climate”. *Climatic Change*. Vol. 81. no. 1, p. 31–52.
- JACOB, Daniela, PETERSEN, Juliane, EGGERT, Bastian, ALIAS, Antoinette, CHRISTENSEN, OleBøssing, BOUWER, LaurensM., BRAUN, Alain, COLETTE, Augustin, DÉQUÉ, Michel, GEORGIEVSKI, Goran, GEORGOPOULOU, Elena, GOBIET, Andreas, MENUT, Laurent, NIKULIN, Grigory, HAENSLER, Andreas, HEMPELMANN, Nils, JONES, Colin, KEULER, Klaus, KOVATS, Sari, KRÖNER, Nico, KOTLARSKI, Sven, KRIEGSMANN, Arne,

- MARTIN, Eric, MEIJGAARD, Erik van, MOSELEY, Christopher, PFEIFER, Susanne, PREUSCHMANN, Swantje, RADERMACHER, Christine, RADTKE, Kai, RECHID, Diana, ROUNSEVELL, Mark, SAMUELSSON, Patrick, SOMOT, Samuel, SOUSSANA, Jean-Francois, TEICHMANN, Claas, VALENTINI, Riccardo, VAUTARD, Robert, WEBER, Björn & YIOU, Pascal [2014]. “EURO-CORDEX : new high-resolution climate change projections for European impact research”. *Regional Environmental Change*. Vol. 14. no. 2, p. 563–578.
- JEONG, D.I., ST-HILAIRE, A., OUARDA, T.B.M.J. & GACHON, P. [2012]. “Multisite statistical downscaling model for daily precipitation combined by multivariate multiple linear regression and stochastic weather generator”. *Climatic Change*. Vol. 114. no. 3-4, p. 567–591.
- JIMÉNEZ-GUERRERO, P., MONTÁVEZ, JP, DOMÍNGUEZ, M, ROMERA, R, FITA, L, FERNÁNDEZ, J, CABOS, WD, LIGUORI, G & GAERTNER, MA [2013]. “Mean fields and interannual variability in RCM simulations over Spain : the ESCENA project”. *Climate Research*. Vol. 57. no. 3, p. 201–220.
- KAIN, John S. [2004]. “The Kain–Fritsch Convective Parameterization : An Update”. *Journal of Applied Meteorology*. Vol. 43. no. 1, p. 170–181.
- KAIN, JS & FRITSCH, JM [1993]. “Convective parameterization for mesoscale models : the Kain-Fritsch scheme. The representation of cumulus convection in numerical models”. *Meteorological Monographs* no. 46. American Meteorological Society, p. 165–170.
- KHAN, Mohammad Sajjad, COULIBALY, Paulin & DIBIKE, Yonas [2006]. “Uncertainty analysis of statistical downscaling methods”. *Journal of Hydrology*. Vol. 319. no. 1–4, p. 357–382.
- KILSBY, C.G., JONES, P.D., BURTON, A., FORD, A.C., FOWLER, H.J., HARPHAM, C., JAMES, P., SMITH, A. & WILBY, R.L. [2007]. “A daily weather generator for use in climate change studies”. *Environmental Modelling & Software*. Vol. 22. no. 12, p. 1705–1719.
- KLEIBER, William, KATZ, Richard W. & RAJAGOPALAN, Balaji [2012]. “Daily spatiotemporal precipitation simulation using latent and transformed Gaussian processes”. *Water Resources Research*. Vol. 48. no. 1. W01523.
- KLEIN, William H., LEWIS, Billy M. & ENGER, Isadore [1959]. “OBJECTIVE PREDICTION OF FIVE-DAY MEAN TEMPERATURES DURING WINTER”. *Journal of Meteorology*. Vol. 16. no. 9, p. 972–682.
- KRINNER, G., VIOVY, Nicolas, NOBLET-DUCOUDRÉ, Nathalie de, OGÉE, Jérôme, POLCHER, Jan, FRIEDLINGSTEIN, Pierre, CIAIS, Philippe, SITCH, Stephen & PRENTICE, I. Colin [2005]. “A dynamic global vegetation model for studies of the coupled atmosphere-biosphere system”. *Global Biogeochemical Cycles*. Vol. 19. no. 1.
- LAMBERT, S. J. & BOER, G. J. [2001]. “CMIP1 evaluation and intercomparison of coupled climate models”. *Climate Dynamics*. Vol. 17. no. 2-3, p. 83–106.
- LAPRISE, R., ELÍA, R. de, CAYA, D., BINER, S., LUCAS-PICHER, P., DIACONESCU, E., LEDUC, M., ALEXANDRU, A. & SEPAROVIC, L. [2008]. “Challenging some tenets of Regional Climate Modelling”. *Meteorology and Atmospheric Physics*. Vol. 100. no. 1-4, p. 3–22.
- LAVAYSSE, C., VRAC, M., DROBINSKI, P., LENGAINNE, M. & VISCHEL, T. [2012]. “Statistical downscaling of the French Mediterranean climate : assessment for present and projection in an anthropogenic scenario”. *Natural Hazards and Earth System Science*. Vol. 12. no. 3, p. 651–670.
- LEVAVASSEUR, G., VRAC, M., ROCHE, D. M., PAILLARD, D., MARTIN, A. & VANDENBERGHE, J. [2011]. “Present and LGM permafrost from climate simulations : contribution of statistical downscaling”. *Climate of the Past*. Vol. 7. no. 4, p. 1225–1246.
- LO, Jeff Chun-Fung, YANG, Zong-Liang & PIELKE, Roger A. [2008]. “Assessment of three dynamical climate downscaling methods using the Weather Research and Forecasting (WRF) model”. *Journal of Geophysical Research : Atmospheres*. Vol. 113. no. D9.
- MACHENHAUER, B., WINDELBAND, M., BOTZET, M., HESSELBJERG, J., DÉQUÉ, M., JONES, G.R., RUTI, P.M. & VISCONTI, G. [1998]. “Validation and Analysis of Regional Present-day Climate and Climate Change Simulations over Europe”. *Max-Planck Institute of Meteorology Report No. 275, 87pp.*
- MARAUN, Douglas, WIDMANN, Martin, GUTIÉRREZ, José M., KOTLARSKI, Sven, CHANDLER, Richard E., HERTIG, Elke, WIBIG, Joanna, HUTH, Radan & WILCKE, Renate A.I. [2015]. “VALUE : A framework to validate downscaling approaches for climate change studies”. *Earth's Future*. Vol. 3. no. 1, p. 1–14.
- MEARNS, L.O., SAIN, S., LEUNG, L.R., BUKOVSKY, M.S., MCGINNIS, S., BINER, S., CAYA, D., ARMITT, R.W., GUTOWSKI, W., TAKLE, E., SNYDER, M., JONES, R.G., NUNES, A.M.B., TUCKER, S., HERZMANN, D., MCDANIEL, L. & SLOAN, L. [2013]. “Climate change projections of the North American Regional Climate Change Assessment Program (NARCCAP)”. *Climatic Change*. Vol. 120. no. 4, p. 965–975.
- MEZGHANI, A. & HINGRAY, B. [2009]. “A combined downscaling-disaggregation weather generator for stochastic generation of multisite hourly weather variables over complex terrain : Development and multi-scale validation for the Upper Rhone River basin”. *Journal of Hydrology*. Vol. 377. no. 3–4, p. 245–260.
- MICHELANGELI, P.-A., VRAC, M. & LOUKOS, H. [2009]. “Probabilistic downscaling approaches : Application to wind cumulative distribution functions”. *Geophysical Research Letters*. Vol. 36. no. 11.

- MORCRETTE, Jean-Jacques [1990]. “Impact of Changes to the Radiation Transfer Parameterizations Plus Cloud Optical Properties in the ECMWF Model”. *Monthly Weather Review*. Vol. 118. no. 4, p. 847–873.
- NABAT, Pierre, SOMOT, Samuel, MALLET, Marc, SEVAULT, Florence, CHIACCHIO, Marc & WILD, Martin [2014]. “Direct and semi-direct aerosol radiative effect on the Mediterranean climate variability using a coupled regional climate system model”. *Climate Dynamics*. P. 1–29.
- NOGUER, M., JONES, R. & MURPHY, J. [1998]. “Sources of systematic errors in the climatology of a regional climate model over Europe”. *Climate Dynamics*. Vol. 14. no. 10, p. 691–712.
- OETTLI, Pascal, SULTAN, Benjamin, BARON, Christian & VRAC, Mathieu [2011]. “Are regional climate models relevant for crop yield prediction in West Africa?” : *Environmental Research Letters*. Vol. 6. no. 1, p. 014008.
- OMRANI, Hiba, DROBINSKI, Philippe & DUBOS, Thomas [2012a]. “Investigation of indiscriminate nudging and predictability in a nested quasi-geostrophic model”. *Quarterly Journal of the Royal Meteorological Society*. Vol. 138. no. 662, p. 158–169.
- OMRANI, Hiba, DROBINSKI, Philippe & DUBOS, Thomas [2012b]. “Spectral nudging in regional climate modelling : how strongly should we nudge?” : *Quarterly Journal of the Royal Meteorological Society*. Vol. 138. no. 668, p. 1808–1813.
- ONOF, C., CHANDLER, R. E., KAKOU, A., NORTHROP, P., WHEATER, H. S. & ISHAM, V. [2000]. “Rainfall modelling using Poisson-cluster processes : a review of developments”. *Stochastic Environmental Research and Risk Assessment*. Vol. 14. no. 6, p. 384–411.
- PALMER, T. N. & SHUKLA, J. [2000]. “Editorial”. *Quarterly Journal of the Royal Meteorological Society*. Vol. 126. no. 567, p. 1989–1990.
- PAVAN, V. & DOBLAS-REYES, F. J. [2000]. “Multi-model seasonal hindcasts over the Euro-Atlantic : skill scores and dynamic features”. *Climate Dynamics*. Vol. 16. no. 8, p. 611–625.
- PERRONE, Thomas J. & MILLER, Robert G. [1985]. “Generalized Exponential Markov and Model Output Statistics : A Comparative Verification”. *Monthly Weather Review*. Vol. 113. no. 9, p. 1524–1541.
- PIANI, C., WEEDON, G.P., BEST, M., GOMES, S.M., VITERBO, P., HAGEMANN, S. & HAERTER, J.O. [2010]. “Statistical bias correction of global simulated daily precipitation and temperature for the application of hydrological models”. *Journal of Hydrology*. Vol. 395. no. 3–4, p. 199–215.
- RADANOVICS, S., VIDAL, J.-P., SAUQUET, E., BEN DAOUD, A. & BONTRON, G. [2013]. “Optimising predictor domains for spatially coherent precipitation downscaling”. *Hydrology and Earth System Sciences*. Vol. 17. no. 10, p. 4189–4208.
- RAJE, Deepashree & MUJUMDAR, P.P. [2010]. “Reservoir performance under uncertainty in hydrologic impacts of climate change”. *Advances in Water Resources*. Vol. 33. no. 3, p. 312–326.
- RICARD, J.L. & ROYER, J.F. [1993]. “A statistical cloud scheme for use in an AGCM.” *Annales Geophysicae*. Vol. 11. no. 12, p. 1095–1115.
- RUTI, P. M., WILLIAMS, J. E., HOURDIN, F., GUICHARD, F., BOONE, A., VAN VELTHOVEN, P., FAVOT, F., MUSAT, I., RUMMUKAINEN, M., DOMÍNGUEZ, M., GAERTNER, M. Á., LAFORE, J. P., LOSADA, T., FONSECA, M. B. Rodriguez de, POLCHER, J., GIORGI, F., XUE, Y., BOUARAR, I., LAW, K., JOSSE, B., BARRET, B., YANG, X., MARI, C. & TRAORE, A. K. [2011]. “The West African climate system : a review of the AMMA model inter-comparison initiatives”. *Atmospheric Science Letters*. Vol. 12. no. 1, p. 116–122.
- SACHINDRA, D. A., HUANG, F., BARTON, A. F. & PERERA, B. J. C. [2014]. “Multi-model ensemble approach for statistically downscaling general circulation model outputs to precipitation”. *Quarterly Journal of the Royal Meteorological Society*. Vol. 140. no. 681, p. 1161–1178.
- SALAMEH, T., DROBINSKI, P., VRAC, M. & NAVEAU, P. [2009]. “Statistical downscaling of near-surface wind over complex terrain in southern France”. *Meteorology and Atmospheric Physics*. Vol. 103. no. 1-4, p. 253–265.
- SANDERS, Frederick [1963]. “On Subjective Probability Forecasting”. *Journal of Applied Meteorology*. Vol. 2. no. 2, p. 191–201.
- SCHMIDL, J., GOODISS, C. M., FREI, C., HAYLOCK, M. R., HUNDECHA, Y., RIBALAYGUA, J. & SCHMITH, T. [2007]. “Statistical and dynamical downscaling of precipitation : An evaluation and comparison of scenarios for the European Alps”. *Journal of Geophysical Research : Atmospheres*. Vol. 112. no. D4.
- SCHNUR, Reiner & LETTENMAIER, Dennis P [1998]. “A case study of statistical downscaling in Australia using weather classification by recursive partitioning”. *Journal of Hydrology*. Vol. 212–213. no. 0, p. 362–379.
- SCHOOF, J.T. & PRYOR, S.C. [2001]. “Downscaling temperature and precipitation : a comparison of regression-based methods and artificial neural networks”. *International Journal of Climatology*. Vol. 21. no. 7, p. 773–790.
- SEMOV, Mikhail A. & STRATONOVITCH, P [2010]. “Use of multi-model ensembles from global climate models for assessment of climate change impacts”. *Climate Research*. Vol. 41. no. 1, p. 1–14.

- SEMENOV, Mikhail A., BROOKS, Roger J., BARROW, Elaine M. & RICHARDSON, Clarence W. [1998]. "Comparison of the WGEN and LARS-WG stochastic weather generators for diverse climates". *Climate Research*. Vol. 10. no. 2, p. 95–107.
- SETH, Anji & GIORGI, Filippo [1998]. "The Effects of Domain Choice on Summer Precipitation Simulation and Sensitivity in a Regional Climate Model". *Journal of Climate*. Vol. 11. no. 10, p. 2698–2712.
- SKAMAROCK, WC, KLEMP, JB, DUDHIA, J, GILL, DO, BARKER, DM, DUDA, MG, HUANG, XY, WANG, W & POWERS, JG [2008]. "A description of the advanced research wrf version 3". *Technical Report, NCAR*.
- SMIRNOVA, Tatiana G., BROWN, John M. & BENJAMIN, Stanley G. [1997]. "Performance of Different Soil Model Configurations in Simulating Ground Surface Temperature and Surface Fluxes". *Monthly Weather Review*. Vol. 125. no. 8, p. 1870–1884.
- SOLMAN, Silvina A., SANCHEZ, E., SAMUELSSON, P., ROCHA, R.P. da, LI, L., MARENGO, J., PESSACG, N.L., REMEDIO, A.R.C., CHOU, S.C., BERBERY, H., LE TREUT, H., CASTRO, M. de & JACOB, D. [2013]. "Evaluation of an ensemble of regional climate model simulations over South America driven by the ERA-Interim reanalysis : model performance and uncertainties". *Climate Dynamics*. Vol. 41. no. 5-6, p. 1139–1157.
- STEHLÍK, Jiří & BÁRDOSSY, András [2002]. "Multivariate stochastic downscaling model for generating daily precipitation series based on atmospheric circulation". *Journal of Hydrology*. Vol. 256. no. 1–2, p. 120–141.
- STEPHENS, Graeme L., L'ECUYER, Tristan, FORBES, Richard, GETTLEMEN, Andrew, GOLAZ, Jean-Christophe, BODAS-SALCEDO, Alejandro, SUZUKI, Kentaroh, GABRIEL, Philip & HAYNES, John [2010]. "Dreary state of precipitation in global models". *Journal of Geophysical Research : Atmospheres*. Vol. 115. no. D24.
- STERN, R. D. & COE, R. [1984]. "A Model Fitting Analysis of Daily Rainfall Data". *Journal of the Royal Statistical Society : Series A (Statistics in Society)*. Vol. 147. no. 1, p. 1–34.
- SUN, Ying, SOLOMON, Susan, DAI, Aiguo & PORTMANN, Robert W. [2006]. "How Often Does It Rain?" : *Journal of Climate*. Vol. 19. no. 6, p. 916–934.
- TAKLE, Eugene S., GUTOWSKI, William J., ARMITT, Raymond W., PAN, Zaitao, ANDERSON, Christopher J., SILVA, Renato Ramos da, CAYA, Daniel, CHEN, Shyh-Chin, GIORGI, F., CHRISTENSEN, Jens Hesselbjerg, HONG, Song-You, JUANG, Hann-Ming Henry, KATZFEY, Jack, LAPENTA, William M., LAPRISE, Rene, LISTON, Glen E., LOPEZ, Philippe, MCGREGOR, John, PIELKE, Roger A. & ROADS, John O. [1999]. "Project to Intercompare Regional Climate Simulations (PIRCS) : Description and initial results". *Journal of Geophysical Research : Atmospheres*. Vol. 104. no. D16, p. 19443–19461.
- VAUTARD, Robert & YIOU, Pascal [2009]. "Control of recent European surface climate change by atmospheric flow". *Geophysical Research Letters*. Vol. 36. no. 22.
- VAUTARD, Robert, GOBIET, Andreas, JACOB, Daniela, BELDA, Michal, COLETTE, Augustin, DÉQUÉ, Michel, FERNÁNDEZ, Jesús, GARCÍA-DÍEZ, Markel, GOERGEN, Klaus, GÜTTLER, Ivan, HALENKA, Tomáš, KARACOSTAS, Theodore, KATRAGKOU, Eleni, KEULER, Klaus, KOTLARSKI, Sven, MAYER, Stephanie, MEIJGAARD, Erik, NIKULIN, Grigory, PATARČIĆ, Mirta, SCINOCCA, John, SOBOLOWSKI, Stefan, SUKLITSCH, Martin, TEICHMANN, Claas, WARRACH-SAGI, Kirsten, WULFMEYER, Volker & YIOU, Pascal [2013]. "The simulation of European heat waves from an ensemble of regional climate models within the EURO-CORDEX project". *Climate Dynamics*. Vol. 41. no. 9-10, p. 2555–2575.
- VIGAUD, N., VRAC, M. & CABALLERO, Y. [2013]. "Probabilistic downscaling of GCM scenarios over southern India". *International Journal of Climatology*. Vol. 33. no. 5, p. 1248–1263.
- VISCHEL, Théo, LEBEL, Thierry, MASSUEL, Sylvain & CAPPELAERE, Bernard [2009]. "Conditional simulation schemes of rain fields and their application to rainfall-runoff modeling studies in the Sahel". *Journal of Hydrology*. Vol. 375. no. 1–2. Surface processes and water cycle in West Africa, studied from the AMMA-CATCH observing system, p. 273–286.
- VRAC, M. & NAVEAU, P. [2007]. "Stochastic downscaling of precipitation : From dry events to heavy rainfalls". *Water Resources Research*. Vol. 43. no. 7, n/a–n/a.
- VRAC, M., STEIN, M. L., HAYHOE, K. & LIANG, X.-Z. [2007a]. "A general method for validating statistical downscaling methods under future climate change". *Geophysical Research Letters*. Vol. 34. no. 18.
- VRAC, M., MARBAIX, P., PAILLARD, D. & NAVEAU, P. [2007c]. "Non-linear statistical downscaling of present and LGM precipitation and temperatures over Europe". *Climate of the Past*. Vol. 3. no. 4, p. 669–682.
- VRAC, M., STEIN, M. L. & HAYHOE, K. [2007d]. "Statistical downscaling of precipitation through nonhomogeneous stochastic weather typing". *Climate Research*. Vol. 34. no. 3, p. 169–184.
- VRAC, M., DROBINSKI, P., MERLO, A., HERRMANN, M., LAVAYSSÉ, C., LI, L. & SOMOT, S. [2012]. "Dynamical and statistical downscaling of the French Mediterranean climate : uncertainty assessment". *Natural Hazards and Earth System Science*. Vol. 12. no. 9, p. 2769–2784.
- VRAC, Mathieu [2012]. "Modélisations statistiques à différentes échelles climatiques et environnementales". "Habilitation à Diriger des Recherches" (HDR - Sciences de l'Environnement, UVSQ) – In Fench, p. 140.

- VRAC, Mathieu & FRIEDERICH, Petra [2015]. “Multivariate—Intervariable, Spatial, and Temporal—Bias Correction”. *Journal of Climate*. Vol. 28. no. 1, p. 218–237.
- VRAC, Mathieu, VAITTINADA AYAR, Pradeebane & YIOU, Pascal [2014]. “Trends and variability of seasonal weather regimes”. *International Journal of Climatology*. Vol. 34. no. 2, p. 472–480.
- VUUREN, Detlef P. van, EDMONDS, Jae, KAINUMA, Mikiko, RIAHI, Keywan, THOMSON, Allison, HIBBARD, Kathy, HURTT, George C., KRAM, Tom, KREY, Volker, LAMARQUE, Jean-Francois, MASUI, Toshihiko, MEINSHAUSEN, Malte, NAKICENOVIC, Nebojsa, SMITH, Steven J. & ROSE, Steven K. [2011]. “The representative concentration pathways : an overview”. *Climatic Change*. Vol. 109. no. 1-2, p. 5–31.
- WILBY, R.L. & WIGLEY, T.M.L. [1997]. “Downscaling general circulation model output : a review of methods and limitations”. *Progress in Physical Geography*. Vol. 21. no. 4, p. 530–548. eprint : <http://ppg.sagepub.com/content/21/4/530.full.pdf+html>.
- WILBY, Robert L, DAWSON, Christian W & BARROW, Elaine M [2002]. “SDSM—a decision support tool for the assessment of regional climate change impacts”. *Environmental Modelling & Software*. Vol. 17. no. 2, p. 145–157.
- WILKS, Daniel S. [2010]. “Use of stochastic weather generators for precipitation downscaling”. *Wiley Interdisciplinary Reviews : Climate Change*. Vol. 1. no. 6, p. 898–907.
- WILKS, Daniel S. [2012]. “Stochastic weather generators for climate-change downscaling, part II : multivariable and spatially coherent multisite downscaling”. *Wiley Interdisciplinary Reviews : Climate Change*. Vol. 3. no. 3, p. 267–278.
- WINGO, Matthew T. & CECIL, Daniel J. [2009]. “Effects of Vertical Wind Shear on Tropical Cyclone Precipitation”. *Monthly Weather Review*. Vol. 138. no. 3, p. 645–662.
- WITTEN, Daniela M., TIBSHIRANI, Robert & HASTIE, Trevor [2009]. “A penalized matrix decomposition, with applications to sparse principal components and canonical correlation analysis”. *Biostatistics*. Vol. 10. no. 3, p. 515–534. eprint : <http://biostatistics.oxfordjournals.org/content/10/3/515.full.pdf+html>.
- XIAOLI, Liu, COULIBALY, P. & EVORA, N. [2008]. “Comparison of data-driven methods for downscaling ensemble weather forecasts”. *Hydrology and Earth System Sciences*. Vol. 12. no. 2, p. 615–624.
- YANG, C., CHANDLER, R. E., ISHAM, V. S. & WHEATER, H. S. [2005]. “Spatial-temporal rainfall simulation using generalized linear models”. *Water Resources Research*. Vol. 41. no. 11, W11415.
- YANG, Wei, BÁRDOSSY, András & CASPARY, Hans-Joachim [2010]. “Downscaling daily precipitation time series using a combined circulation- and regression-based approach”. *Theoretical and Applied Climatology*. Vol. 102. no. 3-4, p. 439–454.
- YEE, Thomas W. [2010]. “The VGAM Package for Categorical Data Analysis”. *Journal of Statistical Software*. Vol. 32. no. 10, p. 1–34.
- YIOU, P. [2014]. “AnaWEGE : a weather generator based on analogues of atmospheric circulation”. *Geoscientific Model Development*. Vol. 7. no. 2, p. 531–543.
- YIOU, P. & NOGAJ, M. [2004]. “Extreme climatic events and weather regimes over the North Atlantic : When and where?” : *Geophysical Research Letters*. Vol. 31. no. 7.
- YIOU, P., VAUTARD, R., NAVEAU, P. & CASSOU, C. [2007]. “Inconsistency between atmospheric dynamics and temperatures during the exceptional 2006/2007 fall/winter and recent warming in Europe”. *Geophysical Research Letters*. Vol. 34. no. 21.
- YIOU, P., SALAMEH, T., DROBINSKI, Ph., MENUT, L., VAUTARD, R. & VRAC, M. [2013]. “Ensemble reconstruction of the atmospheric column from surface pressure using analogues”. *Climate Dynamics*. Vol. 41. no. 5-6, p. 1333–1344.
- ZORITA, Eduardo & STORCH, Hans von [1999]. “The Analog Method as a Simple Statistical Downscaling Technique : Comparison with More Complicated Methods”. *Journal of Climate*. Vol. 12. no. 8, p. 2474–2489.

# Tests de sensibilité des modèles de régionalisation statistique aux biais des GCMs en Climat CTRL et Futur.

Où l'on comprend l'importance de bien évaluer les biais dans les GCMs et l'influence que ce soit sur les variables d'intérêt elle-mêmes ou les sorties de modèles qui en dépendent.

1. Introduction.....	74
2. Publication : Influence of bias correcting predictors on statistical downscaling models.....	77
Résumé étendu . . . . .	77
1. Introduction . . . . .	80
2. Statistical downscaling models and bias correction method . . . . .	82
3. Data and evaluation procedure . . . . .	83
4. Results . . . . .	84
5. Conclusions and discussion . . . . .	94
3. Perspectives.....	99
4. Synthèse des résultats .....	100



## 1. Introduction

Ce chapitre a pour but de répondre à l'*Objectif* n°1.2 de ce manuscrit, à savoir réaliser une étude de sensibilité de modèles de régionalisation statistiques du climat aux biais des GCMs dans un contexte de climat CTRL ou historique et futur.

Les travaux menés dans ce chapitre sont dans la continuité du chapitre précédent. Nous nous appuyerons en partie sur les travaux réalisés précédemment dans un cadre similaire en termes de modèles statistiques et de région d'étude. Bien que les méthodes de correction de biais sont aujourd'hui couramment utilisées pour fournir des simulations climatiques débiaisées ou dans un contexte de downscaling statistique, il n'existe que de rares cas où downscaling et correction de biais sont combinés. Nous nous proposons d'étudier ici les impacts positifs ou négatifs sur les simulations à l'échelle locale selon la correction ou non des prédictors. L'étude portera sur les températures et les précipitations.

La présence des biais dans les GCMs est une chose connue et l'évaluation et l'impact de ces biais sont des questions qui ont généré un certain nombre d'études. Par exemple, CHARLES et al. [2007] ont mis en évidence les impacts de ces biais sur les sorties de précipitations issues de modèles de downscaling statistiques. Dans cette étude, la propagation de ces biais a été étudiée dans les sorties d'un modèle hydrologique forcé par des précipitations downscalées. Dans d'autres études, l'impact de la correction des biais sur des simulations hydrologiques a été étudiée en utilisant des GCMs [HAGEMANN et al., 2011] ou des RCMs [SAURRAL et al., 2013] corrigés en entrée de modèles hydrologiques. Ces études montrent l'importance d'avoir des données corrigées en entrée d'un modèle hydrologique (et d'impacts en général).

A la suite des travaux menés au CHAPITRE II, une collaboration a vu le jour dans le cadre du projet StaRMIP<sup>1</sup> avec HydroSciences Montpellier. Cette collaboration avait pour but de discriminer des modèles de réduction d'échelle statistique par le biais du modèle hydrologique conceptuel GR4j [PERRIN et al., 2003]. Pour ce faire, ce dernier a été forcé par des simulations downscalées de températures et de précipitations en climat historique (1986-2005). Nous reprendrons quelques résultats de cette étude pour illustrer la nécessité de l'étude menée dans ce chapitre. Nous rappelons que l'évaluation se fait ici uniquement en termes de simulations hydrologiques. La FIGURE III.1 illustre la méthode utilisée pour comparer, par un test de sensibilité hydrologique, les différents modèles de downscaling statistique.

Dans cette étude, nous produisons douze simulations hydrologiques pour quatre bassins versants. Elles ont été obtenues à partir d'un modèle hydrologique calibré à partir de données d'observations. Ce modèle hydrologique a ensuite été forcé par des données issues de trois jeux de données à grande échelle que sont les réanalyses NCEP [KALNAY et al., 1996] et les GCMs IPSL-CM5-MR [DUFRESNE et al., 2013] et CNRM-CM5 [VOLDOIRE et al., 2013]. Ces trois jeux de données ont été utilisés de façon brute (raw) ou downscalés par trois modèles statistiques (Analog, CDFt et SWG), ce qui fait douze simulations. Plus de détails concernant les données, les modèles statistiques et le modèle hydrologique sont disponibles dans GROUILLET et al., 2015, (*cf.* <http://www.hydrol-earth-syst-sci-discuss.net/12/10067/2015/hessd-12-10067-2015.html>).

---

1. <http://starmip.lsce.ipsl.fr/>

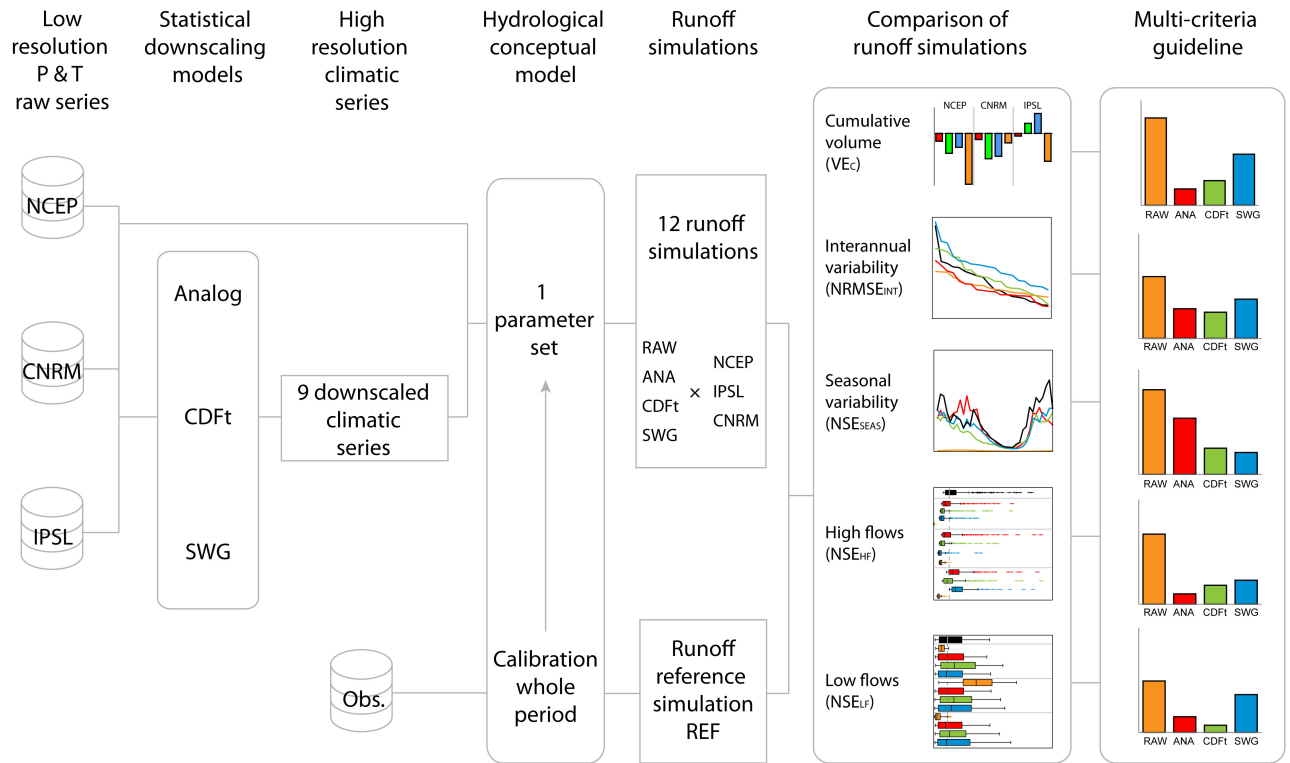


FIGURE III.1 – Figure 5 de l'article GROUILLET et al. [2015] – Flow chart illustrating the method used to compare the three downscaling methods through a hydrological sensitivity analysis.

La FIGURE III.2 représente les hydrographes des débits mensuels des différentes simulations. Nous étudions ainsi le cycle saisonnier de ces débits simulés. Les courbes jaunes représentent les simulations forcées par les données brutes à grande échelle, en rouge les simulations forcées par les données downscalées par Analog, en vert par CDFt et en bleu par SWG (rappelons que les modèles de downscaling Analog et SWG ont été calibrés par NCEP). En noir, nous avons les courbes des simulations de référence (réalisées à partir de données d'observations). Ces hydrographes sont évalués en utilisant le coefficient d'efficacité de Nash–Sutcliffe [NSE, NASH & SUTCLIFFE, 1970] :

$$NSE = 1 - \frac{\sum_{t=1}^N (Q_{obs}^t - Q_{sim}^t)^2}{\sum_{t=1}^N (Q_{obs}^t - \bar{Q}_{sim})^2}. \quad (III.1)$$

Où  $Q_{obs}^t$  and  $Q_{sim}^t$  sont respectivement les débits observés et simulés au pas de temps  $t$ ,  $N$  le nombre de pas de temps (mensuel ici) pour lesquels les observations sont disponibles. Un NSE proche de 1 signifie une correspondance parfaite entre les valeurs observées et simulées alors qu'un NSE négatif signifie que les valeurs simulées sont de moins bonne qualité que si elles étaient remplacées par la moyenne des observations.

Cette figure nous montre l'apport incontestable des modèles de réduction d'échelle. En effet, les réponses hydrologiques issues des GCMs brutes présentent en général des NSE négatifs. Lorsque ce sont les données downscalées qui servent à forcer le modèle hydrologique, les simulations ont la plupart du temps un NSE positif. Il faut néanmoins faire attention à SWG. Dans les cas où c'est NCEP qui est downscalée, la réponse hydrologique issue de SWG est la meilleure ou est parmi les meilleures en fonction du bassin considéré. Dans les cas de CNRM et IPSL downscalées, SWG génère

des précipitations trop fortes. Ceci entraîne des débits irréalistes caractérisés par des NSEs fortement négatifs qui sont plus petits que ceux obtenus à partir des GCMs bruts.

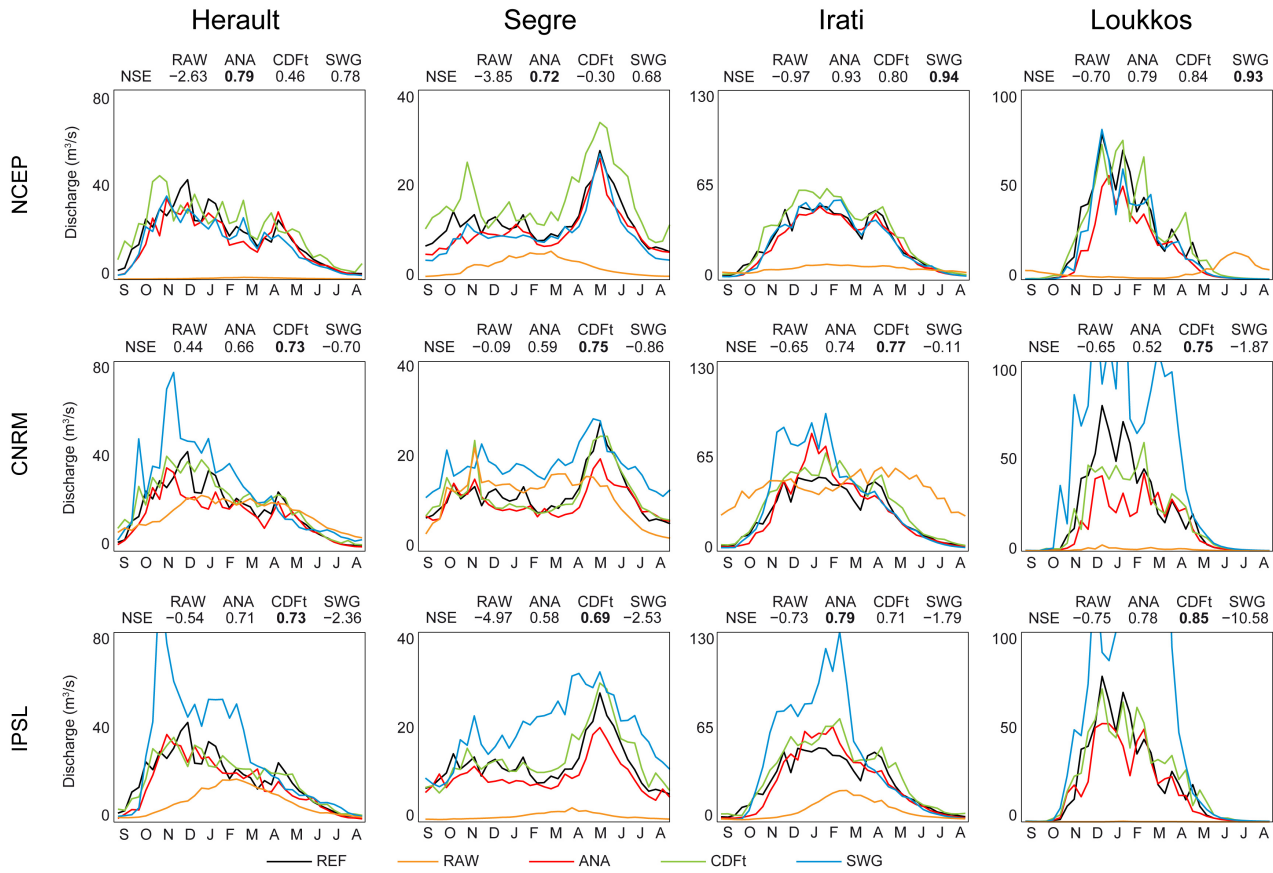


FIGURE III.2 – Figure 9 de l'article GROUILLET et al. [2015] – Comparison of seasonal variations in streamflow simulated using REF data, RAW (NCEP or GCM) data, and the three downscaling methods (applied to NCEP, CNRM and IPSL) for each basin. The NSE values for the mean 10 day discharge between REF and the simulation concerned are given above each panel. The best values are in bold.

Au delà de cette étude de saisonnalité, des analyses en termes de biais de volume total, de variabilité interannuelle des débits et de distributions des débits journaliers les plus forts et les plus faibles ont été menées. Ces analyses ne seront pas détaillées ici. D'un point de vu général, quelles que soient les données à grande échelle les simulations issues du modèle ANALOG sont globalement les meilleures suivi de celles issues de CDFt. Dans le cas des simulations issues de SWG, les simulations hydrologiques sont de bonne qualité lorsque les prédictors sont issus de NCEP. Cependant, les biais des GCMs par rapport à NCEP induisent des simulations hydrologiques médiocres. Cette étude nous montre clairement l'influence négative des biais des GCMs sur les simulations de précipitations et de températures des SDMs qui à leur tour biaisent les simulations hydrologiques. Pour remédier à cela, une solution est de corriger les GCMs par rapport aux réanalyses [e.g., COLETTE et al., 2012 dans un contexte de downscaling dynamique].

Ceci motive les travaux réalisés dans la suite de ce chapitre qui seront présentés sous la forme d'un article (soumis dans journal of climate), donné à la SECTION 2 et précédé d'un résumé en français.

## 2. Publication : Influence of bias correcting predictors on statistical downscaling models

### Résumé étendu

L'objectif de cet article est d'étudier l'influence de la correction des biais dans les GCMs sur les sorties des modèles de downscaling statistique en climat CTRL et futur. Ce résumé suit la progression de l'article en se focalisant sur trois points : le cadre statistique comprenant la procédure de correction de biais et les modèles de downscaling décrits à la section 2 de l'article, les données utilisées en tant que prédicteurs et prédictands et la procédure d'évaluation décrits dans la section 3 de l'article et enfin les différents résultats et conclusions décrits aux sections 4 et 5 de l'article.

**N.B.** : la première section de l'article n'est pas résumée car elle concerne des points déjà évoqué en détails dans ce manuscrit (l'introduction de l'article, encore en cours de rédaction, correspond en partie à l'introduction de ce chapitre) notamment au CHAPITRE I, SECTION 3 de ce manuscrit. Un lecteur pressé pourra donc aller directement à la section 2 de l'article.

---

### *Cadre statistique : modèles et procédure de correction*<sup>1</sup>

Dans cette étude, seuls des modèles de downscaling statistique sont étudiés : quatre modèles pour les températures et trois pour les précipitations ont été choisis en se basant sur l'article du chapitre précédent [*cf.* VAITTINADA AYAR et al., 2015 pour plus de détails techniques sur les modèles]. Nous avons les modèles suivants :

- pour les températures : CDFt [VRAC et al., 2012], GAM [HASTIE & TIBSHIRANI, 1990], SWG [CHANDLER & WHEATER, 2002] et ANALOG [ZORITA & STORCH, 1999] ;
- pour les précipitations : CDFt , SWG et ANALOG.

La méthode CDFt servira également à la correction des biais des GCMs en entrée des SDMs. Cette correction s'effectue de façon mensuelle de même que pour CDFt utilisé en tant que SDM. Les autres SDMs – SWG, ANALOG et GAM – sont calibrés sur chaque saison usuelle de l'hémisphère nord (i.e., quatre calibrations par SDM : hiver (DJF), printemps (MAM), été (JJA), automne (SON)). Les simulations sont également effectuées de façon saisonnière.

### *Données et procédure d'évaluation*<sup>2</sup>

De la même façon qu'au chapitre précédent, les SDMs nécessitent des prédictands et des prédicteurs. Les observations sont issues de la base de données E-OBS version 11 [HAYLOCK et al., 2008]. Le choix des prédicteurs se fait en se basant sur l'article du CHAPITRE II sur la zone géographique  $[-52.875^{\circ}\text{E} ; 76.50^{\circ}\text{E}] \times [20.25^{\circ}\text{N} ; 72.00^{\circ}\text{N}]$ . Ils sont tirés de trois bases de données :

---

1. section 2 de l'article  
2. section 3 de l'article

- ERA-interim à la résolution  $1.125^\circ \times 1.125^\circ$ , sur la période 1979-2005 ;
- le modèle global IPSL-CM5-MR à la résolution  $1.25^\circ \times 2.5^\circ$  ;
- le modèle global CNRM-CM5 à la résolution  $1.4^\circ \times 1.4^\circ$ .

Les GCMs sont choisis sur la période historique (1950-2005) et future (2006-2100) sous le scénario RCP8.5 et sont regrillés à la résolution d'ERA-I. Excepté CDFt qui utilise la variable d'intérêt à grande échelle comme prédicteur les autres modèles utilisent plusieurs variables. Le TABLEAU III.1 résume les prédicteurs choisis en fonction du prédicteand (*cf.* CHAPITRE II pour la méthode de sélection des prédicteurs).

Prédicteand	D2	SLP	T2	U850	V850	Z850	PR
<b>Précipitation</b>	✓	✓	✓	✓	✓	✓	✓
<b>Température</b>	-	✓	✓	✓	✓	✓	-

Tableau III.1 – Prédicteurs en fonction du predictand : la température de rosée à 2m (D2), la température à 2m (T2), la pression au niveau de la mer (SLP), les composantes zonale et méridionale du vent et la hauteur du géopotential au niveau de pression de 850 hPa (U850, V850 and Z850), les précipitations à grande échelle (PR).

Les SDMs sont calibrés à partir des réanalyses (sur la période 1979-2005) et des données E-OBS et forcés par les réanalyses, les GCMs bruts et corrigés sur la période historique et future. La correction des GCMs est faite à l'aide de CDFt et avec ERA-I comme référence.

Les séries temporelles downscalées forcées par ERA-I serviront de référence pour évaluer les séries temporelles downscalées forcées par les GCMs, le but étant d'évaluer les biais des simulations forcées par des GCMs et les améliorations potentielles lorsque les prédicteurs sont corrigés sur la période historique (1979-2005). Ensuite, l'évolution des simulations downscalées à partir des GCMs bruts et corrigés entre la période historique (1979 - 2005) et future (2071 - 2100) est évaluée. Enfin, la stationnarité temporelle des changements apportés par la correction de biais entre la période historique et future est évaluée. Toutes ces évaluations sont faites en termes de moyenne et de variance des séries temporelles.

### *Principaux résultats et conclusions*<sup>1</sup>

Les résultats sont uniquement exprimés en terme de moyennes et de variances en calculant les biais sur la période historique (1979-2005) entre des simulations forcées par les GCMs et les réanalyses, l'évolution des projections entre la période 1976-2005 et 2071-2100 et les changements dans ces évolutions. La conclusion majeure de cette étude est la mise en évidence de l'influence de la correction de biais des GCMs sur les simulations. De façon générale, nous pouvons dire que cela améliore sensiblement les simulations. Cette influence dépend néanmoins de la variable d'intérêt et du SDM considéré. Elle diffère également en fonction de si nous considérons la moyenne ou la variance et varie d'un endroit à un autre du domaine d'étude.

Ces résultats sont résumés dans les TABLEAUX 1 à 3 de l'article.

1. sections 4 et 5 de l'article

Cette étude permet une meilleure interprétation et une meilleure utilisation des simulations issues des modèles de régionalisation statistique utilisant des prédicteurs provenant des GCMs que ces derniers soient corrigés ou non.

Cette étude amène plusieurs perspectives intéressantes, par exemple :

- élargir le nombre de méthodes de correction de biais et de GCMs ;
- appliquer la correction aux données GCMs utilisée en entrée des RCMs ;
- appliquer les différentes évaluations en utilisant des prédicteurs issus des RCMs pour étudier l'influence de la résolution et des couplages physiques sur les sorties de SDMs.

Ces perspectives sont abordées dans l'article. Nous reviendront sur certaines d'entre elles à la SECTION 3 de ce chapitre.

## Influence of bias correcting predictors on statistical downscaling models

MATHIEU VRAC<sup>1</sup>, PRADEEBANE VAITTINADA AYAR<sup>1</sup>

<sup>1</sup> Laboratoire des Sciences du Climat et de l'Environnement (LSCE-IPSL, CNRS)

Centre d'Etudes de Saclay, Orme des Merisiers, 91190 Gif-sur-Yvette, France

Corresponding author : Dr. Mathieu Vrac, mathieu.vrac@lsce.ipsl.

### Abstract

If bias correction (BC) methods for climate simulations and statistical downscaling models (SDMs) are common to provide debiased and regional climate projections, the influence of bias correcting the large-scale predictors of SDMs has not been investigated while this may have some impacts on the local-scale statistical simulations: such an investigation for daily temperature and precipitation is therefore the goal of the present study. Hence, four temperature SDMs and three precipitation ones are calibrated on reanalyses and observed data over a historical time period.

First, the SDMs are forced by historical predictors coming from two GCMs either corrected or not. The two types of simulations are compared to SDM simulations driven by reanalyses, characterizing the improvements or degradations of the statistical simulations.

Second, the evolutions of basic statistical properties of the SDM simulations are compared, driven by bias corrected or raw predictors from GCM future projections, and with the evolutions of the raw GCM projections.

Finally, the stationarity of the changes (of the SDM simulations) brought by the BC of the predictors is investigated in terms of means and variances. Those changes are computed over a historical (1976-2005) and future (2071-2100) time period and compared to assess the (non-) stationarity.

Globally, bias correction can have important impacts on the SDM simulations although its influence vary from one SDM to another, with different spatial structures, and depends on the considered statistical properties. Nevertheless, the corrected predictors generally improves the historical pro-

jections, can impact their future evolutions, with potentially strong non-stationary behaviors.

---

### 1. Introduction

The need for downscaling climate simulations is present for many studies, and in particular for many studies related to impacts of climate change. Indeed, if Global Climate Models (GCMs) are the main tools for projecting future climate evolutions, the spatial resolution of their outputs is generally still too coarse (from about 100km to 300km) to drive impact models and lead associated impact studies [e.g., IPCC, 2013]. Hence, downscaling models have been and are still extensively developed and applied to generate climate values (temperature, precipitation, etc.) at regional, local, or station scales. Now well established in the literature, those models are said to be either "dynamical" or "statistical". While dynamical downscaling explicitly solves the physical equations of the atmosphere at a regional scale – through the so-called "Regional Climate Models" [e.g., Laprise et al., 2008; Rummukainen, 2010] –, statistical downscaling is based on statistical relationships and models to link large-scale (atmospheric, environmental, etc.) information called "predictors" to local-scale variables of interest called "predictands". Both approaches have been widely tested and evaluated on many climate variables, and have also been intercompared [e.g., Schmidli et al., 2007; Vaittinada Ayar et al., 2015 among others].

A statistical downscaling model (SDM) has however some particularities with respect to RCMs. The major one is certainly that it is not directly based on physical equations. It therefore requires

large- and local-scale data for its calibration [see e.g., Maraun et al., 2010; Vaithinada Ayar et al., 2015 for further discussions between RCMs and SDMs]. As such, when a statistical downscaling model is applied in climate change context (i.e., driven by GCM future projections as predictors), some underlying hypotheses are made [Hewitson & Crane, 1996]: (A) The statistical model – calibrated under present or recent past conditions – remains valid under modified climate conditions; (B) The predictors used as input into the SDM are relevant and completely represent the climate change signal; (C) The predictors used as input into the SDM are correctly represented and simulated by the GCM. Although the evaluation of those hypotheses is rarely performed (or only partially when it is the case) before applying any SDM, some methods exist to assess the capability of SDMs to reproduce the statistical properties of observations when calibrated and driven by reanalysis data [Huth, 1999; Robertson et al., 2004; Vrac et al., 2007d] or driven by GCM or RCM simulations [Charles et al., 1999; Charles et al., 2004; Wilby & Wigley, 2000]. Other approaches have been tested to evaluate the robustness of the SDMs in time, in comparing SDMs future projections to those from GCMs [e.g., Frías et al., 2006] or from RCMs [e.g., Wood et al., 2004; Haylock et al., 2006]. Vrac et al., 2007a have also developed a method for evaluating SDMs under CTRL climate (reanalyses vs. GCMs) and under future climate for which RCM future projections are considered as “pseudo-observations” that can be compared SDM future simulations [see also Gaitan et al., 2014 for applications]. Many of those studies showed that validating a SDM in present day conditions does not imply legitimacy for the SDM projections in changed climate conditions [e.g., Charles et al., 1999] and, moreover, that predictors coming from a GCM – by opposition to reanalyses – to drive a SDM can lead to poor performances of the SDM, due to biases of those predictors with respect to reanalyses [e.g., Charles et al., 2004; Grouillet et al., 2015]. Indeed, if climate model simulations have seen their quality improved over the last years and decades, they still have some biases in the sense that their statistical distribution differs from that of observations [Meehl, 2007; Christensen et al., 2008; White & Toumi, 2013; Vrac & Friederichs,

2015]. Hence, in parallel of climate model developments, statistical bias correction (BC) methods have also been designed to adjust climate simulations by transforming the simulated data into new data with no or at least fewer statistical biases with respect to reference [e.g., Haddad & Rosenfeld, 1997; Gudmundsson et al., 2012; Vrac et al., 2012]. It is therefore logical to wonder if and how bias correction methodologies applied to predictors derived from GCM simulations can affect the realism and the quality of the SDM projections under present and future conditions. In other words, even if hypothesis (C) is not completely verified – i.e., the predictors used as input into the SDM are not correctly simulated by the GCM –, what are the impacts (in terms of SDM outputs) of bias correcting those GCM-derived predictors before performing a SDM? Some studies, such as Colette et al. [2012] or White & Toumi [2013], have investigated such a question for dynamical downscaling. They found that, although it can produce undesirable results in the RCM simulations, such a prior correction of the large-scale inputs for RCMs with a quantile-association based method clearly improves the quality of the RCM simulations. However, this question has never been addressed for statistical downscaling and this is therefore the main goal of the present article, for temperature and precipitation.

To tackle this question, as SDM simulations may differ from one SDM to another, four (three) different SDMs are employed for temperature (precipitation). Moreover, preliminary analyses indicated that specific bias correction methods do not strongly change the main conclusions of this study (not shown). Hence, only one BC method is used in the following. Both BC and SDMs are presented in SECTION 2. The different datasets used are presented in SECTION 3 and comprise the reference datasets (one for the BC, one for the historical SDM evaluations) as well as the two GCMs and the reanalyses, both providing large-scale predictors. This Section also describes the evaluations in historical and future contexts. Results are provided in SECTION 4 not only (i) for historical biases, but also for future comparisons in terms of (ii) evolutions of statistical properties for temperature and precipitation from present to



future periods, as well as in terms of (iii) stationarity of the BC influence between present and future periods. General conclusions are given in SECTION 5, along with discussions and perspectives of this study.

## 2. Statistical downscaling models and bias correction method

Four SDMs are tested for temperature and three for precipitation. Those models were selected based on the evaluation study performed in Vaithinada Ayar et al. [2015]. For temperature, the four SDMs are the following: the “Cumulative Distribution Function - transform” approach [CDFt, e.g., Michelangeli et al., 2009; Vrac et al., 2012 ]; a conditional “stochastic weather generator” [SWG, e.g., Chandler & Wheeler, 2002 ]; a model based on analogs [ANALOG, e.g., Zorita & Storch, 1999 ]; a “Generalized Additive Model” [GAM, Hastie & Tibshirani, 1990 ]. For precipitation downscaling, CDFt, SWG and ANALOG are used but not GAM that achieved too poor performances [Vaithinada Ayar et al., 2015]. Those models are briefly sketched here for a short reminder but all details can be retrieved in Vaithinada Ayar et al., 2015 and references therein.

The CDFt approach relates the local-scale CDF of the variable of interest to the associated large-scale CDF through a “quantile-quantile” approach performed between the future large- and local-scale CDFs – and not between present CDFs as in the classical quantile-quantile method. To do so, the future local-scale CDF is first estimated based on an assumption of a mathematical transformation to link the evolution of the large-scale CDF to the evolution of the local-scale one. Hence, CDFt and quantile-quantile methods are philosophically close to each other, but CDF-t accounts for the CDF changes from the calibration to the projection (or future) time periods. All theoretical and technical details are given in Vrac et al. [2012]. Note that, contrary to SWG, ANALOG and GAM that require to be calibrated with large-scale reanalysis data as predictors before to be applied to GCM data, the CDFt model directly establishes a link between the GCM and local-scale CDFs. No calibration based on real-time predictors is needed. This is a specificity of some “Model Output Statis-

tics” approaches by opposition to “Perfect-Prog” models [see e.g., Maraun et al., 2010; Vaithinada Ayar et al., 2015 for details].

In the present study, CDFt is used both as a statistical downscaling model and as a bias correction method. Indeed, it is CDFt that will be used to bias correct GCM outputs with respect to reanalysis data to provide inputs to the different SDMs.

In the stochastic weather generator (SWG) employed in this study, a two-step approach is implemented to model precipitation in a “Vectorised Generalized Linear Models” (VGLM) framework as in Chandler & Wheeler [2002]. First, the rainfall occurrence is modelled through a logistic regression [e.g., Buishand et al., 2004; Fealy & Sweeney, 2007 ], allowing to characterize the probability  $p_i$  of rainfall occurrence for a given day  $i$  conditionally on atmospheric predictors (or covariates)  $\mathbf{X}_i$ . Then, the probability density function (pdf) of the rain intensity (given that it rains) is assumed to be a Gamma distribution whose the logarithms of the shape  $\alpha$  and rate  $\beta$  parameters are linear functions of the large-scale predictors  $\mathbf{X}_i$  at day  $i$ . See Vaithinada Ayar et al. [2015] for mathematical formulations. For temperature, a single step is used, where temperature at day  $i$  is supposed to follow a Gaussian distribution with the mean  $m$  and the logarithm of the standard deviation  $\sigma$  linearly dependent on  $\mathbf{X}_i$ .

The ANALOG method is applied here in its deterministic form, as defined for example in Zorita & Storch [1999]; Yiou et al. [2007]; Vautard & Yiou [2009]. For each given day to be downscaled in the projection period, ANALOG consists in finding the day in the calibration period that has the closest atmospherical situation (i.e., predictors  $\mathbf{X}_i$ ) according to a chosen distance (or similarity) metric. Many distances have been employed [e.g., Grenier et al., 2013 ] but the Euclidian distance is used here.

For temperature downscaling, a fourth model is also used based on “Generalized Additive Models” [GAM, Hastie & Tibshirani, 1990 ]. GAM is a deterministic model characterizing the expectation of the local-scale predictand (here, the temperature) at day  $i$ , conditionally on the large-scale predictors  $\mathbf{X}_i$  as a sum of spline functions  $f_j(X_j)$

(here cubic regression splines). Such a downscaling method has been applied under present climate conditions, for instance to downscale temperature [Vaithinada Ayar et al., 2015] or near surface wind fields [Salameh et al., 2009], or under past climate as the Last Glacial Maximum time period (-21 ky) to reconstruct monthly temperature and precipitation climatology over Western Europe [Vrac et al., 2007c] or global permafrost [Levvasseur et al., 2011]. This approach is said to be “data-driven” since it allows to model both piecewise linearities and non-linearities depending on the nature of the predictor-predictand dependence (in other words, the complexity of the model is not fixed by the user but determined by the data).

All mathematical formulations and technical details about those four SDMs are given in Vaithinada Ayar et al. [2015] and therein references.

The bias correction of the GCMs through CDFt is applied on a monthly basis (i.e., 12 CDFt models are applied for each predictor and GCM). CDFt as SDM is also applied on a monthly basis. However, the other SDMs – SWG, ANALOG and GAM – are calibrated and applied on a seasonal basis with the traditional North-hemisphere 3-month seasons (i.e., four calibrations per SDM): Winter (DJF), Spring (MAM), Summer (JJA), Autumn (SON). Preliminary analyses with other configurations (e.g., monthly based calibrations for all models) did not show any significant differences in the conclusions presented later in this article (not shown).

### 3. Data and evaluation procedure

#### 3.1. Reference and model data

For the calibration of most of the statistical downscaling models, two types of data are needed: local-scale observations of the variable of interest (predictand) and large-scale variables (predictors). In the present study, the daily local-scale predictand (i.e., temperature and precipitation) come from the E-OBS gridded dataset [Haylock et al., 2008] obtained through an interpolation procedure from “European Climate Assessment & Dataset” (ECA&D) time series at meteorological stations [Klok & Klein Tank, 2009]. The E-OBS version used in this study is the version 11 (released date:

April 2015) and covers inland Europe on a rotated grid with a spatial resolution of  $0.44^\circ$  from 1950 to 2014 at a daily time-step.

The large-scale predictors come from ERA-Interim reanalyses [Dee et al., 2011] – hereafter referred to as ERA-I – taken at the  $1.125^\circ \times 1.125^\circ$  spatial resolution, from 1979 to 2005.

Except for CDFt that only uses the large-scale variable of interest as predictor, the other SDMs tested in this study are using several predictors. For temperature, the predictors are: the temperature at 2m (T2), the sea level pressure (SLP), the eastward wind, the northward wind and the geopotential height at the 850 hPa pressure level (U850, V850 and Z850). For precipitation, the same predictors are employed with in addition the dew point at 2m (D2) and the large-scale precipitation (PR). All the predictors are extracted over the region  $[-52.875^\circ\text{E} ; 76.50^\circ\text{E}] \times [20.25^\circ\text{N} ; 72.00^\circ\text{N}]$ . More precisely, based on those data, for ANALOG the predictors are the fields of anomalies of those variables with respect to the seasonal cycle while for SWG and GAM they are the first principal component (PC) of a principal component analysis [PCA, Barnston & Livezey, 1987] performed on each predictor separately. For discussion on the choice of those predictors, see Vaithinada Ayar et al. [2015].

The daily predictors needed for the SDMs have also been extracted from two GCMs to drive the different SDMs over historical (1950-2005) and future (2006-2100) time periods under RCP8.5 scenario [IPCC, 2013]: the IPSL-CM5-MR global climate model with a  $1.25^\circ \times 2.5^\circ$  resolution, developed at “Institut Pierre Simon Laplace” [Marti et al., 2010; Dufresne et al., 2013]; and the CNRM-CM5 global climate model [Voldoire et al., 2013] with a  $1.4^\circ \times 1.4^\circ$  resolution, developed at “Météo-France”. All GCM variables used as predictors into the SDMs have been regridded to the  $1.125^\circ \times 1.125^\circ$  ERA-I spatial resolution. Hence, the SDMs (calibrated with reanalyses) are then forced either by the raw (regridded) predictors or by the bias corrected (regridded) predictors, both over the historical and future (2006-2100) time periods. As mentioned in SECTION 2, the bias correction of those GCM-based predictors is performed through

CDFt and the BC references are the ERA-I re-analyses.

### 3.2. Historical evaluations and Future comparisons

The impact of bias correcting GCM predictors before incorporating them into statistical downscaling models (SDMs) is first studied over a historical period where observed data are available. In this context, the SDMs are first calibrated over the 1979-2005 time period to link the ERA-I predictors to the E-OBS data used as reference. Note that the predictors depend on the SDM of interest, see SECTION 3.1. In a next step, the predictors are taken from GCM to drive the SDMs and provide downscaled simulations. Those GCM predictors can be used either directly as input into the SDMs, or in a corrected version, i.e., with a bias correction (BC) method applied to them to make their distribution as close as possible to that of the ERA-I initial predictors. Those two types of predictors – hereafter referred to as “raw” and “bias corrected” predictors respectively – are extracted or calculated over the 1979-2005 time period in order to drive the SDMs over the same time period. The evaluations are performed by comparison of those GCM-driven downscaled time series to the ERAI-driven downscaled time series. Note that the real values of the predictands (i.e., E-OBS) are not used for evaluation since the goal is here to evaluate (i) the biases of SDM simulations when using GCM outputs as predictors instead of re-analyses and (ii) the potential gain in SDM results when correcting those predictors. Indeed, the evaluation of those various simulations against real observations would make difficult to distinguish the biases brought by the SDM itself from the biases brought by the predictors. Working with SDMs driven by predictors from ERAI as evaluation reference allows to ease the interpretation and to focus directly on the predictors themselves, without considering the quality (with respect to EOBS) of the SDMs. Note that the quality and biases of the SDM with respect to E-OBS have been studied in Vaittinada Ayar et al., 2015.

In a future projection context, there is obviously no observed or reference data available for evaluation of the simulations. However, the goal is here

to evaluate the differences between the projections obtained with raw GCM predictors-driven SDMs, and those obtained from the bias corrected GCM predictors-driven SDMs, as well as between the different SDMs. To perform such a task, the SDMs are first calibrated as before over the 1979-2005 time period between the predictors from the ERA-I reanalyses and the reference E-OBS data. Then, GCM predictors – in their raw or bias corrected version – over the years 2006-2100 are provided as input into the calibrated SDMs. In all the following, the analyses are performed according to one future time period: 2071-2100. Based on this approach, it is possible to compare, for a given SDM and the given future time period, the evolution of the SDM simulations when driven by raw or corrected predictors. To do so in a coherent way, all temporal evolutions are computed with respect to the outputs of the associated method over the 1979-2005 time period: i.e., the raw GCM driven-SDM evolution is computed with respect to the raw GCM driven-SDM simulations for 1979-2005, and equivalently for the corrected GCM driven-SDM approaches.

Moreover, relying on the SDM historical and future projections (from raw and bias corrected predictors), it is also possible to study the temporal stationarity of the changes brought by the BC of the predictors. Those changes can indeed be computed over the historical (1976-2005) and future (2071-2100) time periods and compared to assess the potential (non-) stationarity.

## 4. Results

In all the following, results are only shown for the CNRM GCM and mostly for the Winter (DJF) season. However, conclusions are very similar from the IPSL outputs instead of CNRM and for the other seasons. Summer CNRM results as well as Winter and Summer IPSL results are provided for illustrations as auxiliary material.

### 4.1. Evaluation on the historical period

In this sub-section, analyses will rely on “biases” of SDM outputs. Those biases are defined as differences between SDM projections driven either by corrected or non-corrected predictors, and SDM outputs driven by reanalysis data as predictors.

The underlying idea is that SDM outputs driven by reanalyses provide somehow the best results that can be obtained with SDMs. For an evaluation of the biases of reanalyses-driven SDMs, see Vaittinada Ayar et al. [2015]. Figures 1 and 2 show

differences of mean winter biases, i.e., “biases of SDM(BC) - biases of SDM(raw)”, from the SDMs driven by the CNRM outputs as predictors, respectively for temperature (in  $^{\circ}$ ) and precipitation (relative biases in %).

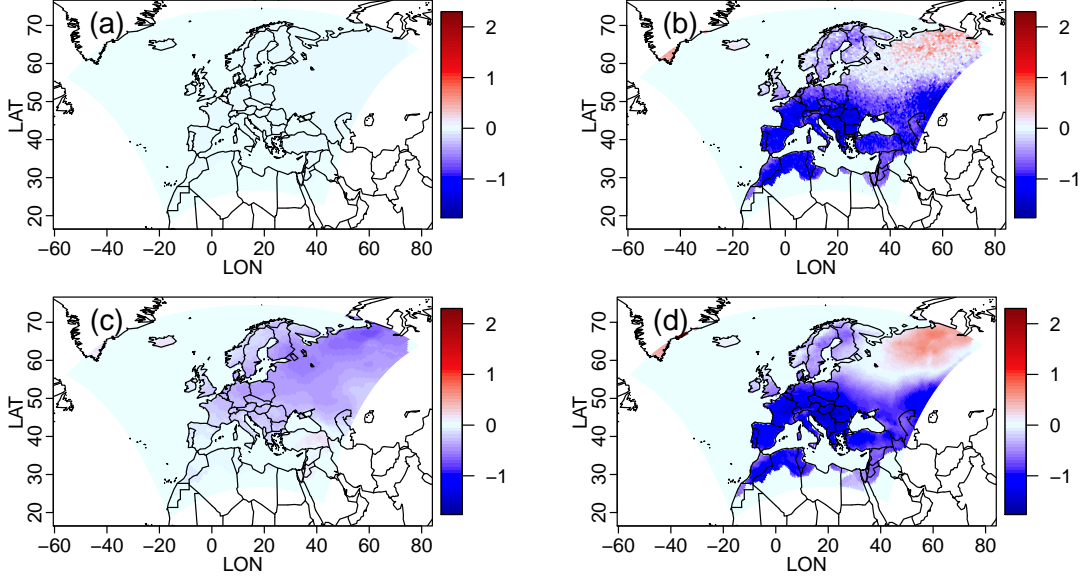


Figure 1: Differences of temperature biases between SDM simulations driven by corrected CNRM predictors (biases of SDM(BC)) or non-corrected CNRM predictors (biases of SDM(raw)), i.e., “biases of SDM(BC) - biases of SDM(raw)”: (a) CDFt, (b) SWG, (c) ANALOG, (d) GAM.

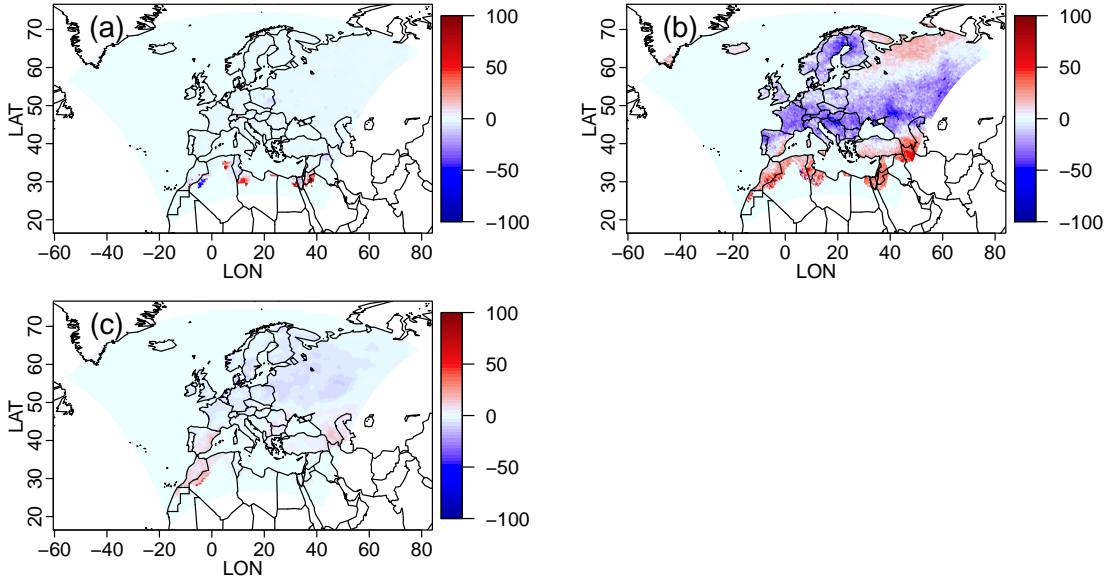


Figure 2: Differences of relative biases (in %) between SDM precipitation simulations driven by corrected CNRM predictors (biases of SDM(BC)) or non-corrected CNRM predictors (biases of SDM(raw)), i.e., “biases of SDM(BC) - biases of SDM(raw)”: (a) CDFt, (b) SWG, (c) ANALOG.

Hence, negative values indicate smaller biases for an SDM driven by corrected predictors than for an SDM driven by raw (i.e., uncorrected) predictors.

CDFt presents very close to zero differences of seasonal biases for both temperature and precipitation (panels (a) in Figs. 1 and 2). This indicates

that the correction of the “large-scale” temperature or precipitation – or more generally the bias correction of the only predictor used as input in CDFt – does not impact the downscaling results provided by CDFt. This model simply adapts the CDF transformation to the inputs. Note also that the small differences between results from raw or corrected predictors can be explained by the already satisfying results of CDFt (at least in terms of biases) when driven by uncorrected predictors. For SWG (panels (b) in Figs. 1 and 2), the differences of biases are not as close to zero as for CDFt. For the major part of the domain, the differences are significantly negative. Therefore, bias correcting the predictors used in SWG improves the quality of the downscaling results. However, this is not true everywhere. For example, the North-East part of the domain for temperature and precipitation, as well as the Southern Mediterranean basin for precipitation show positive differences of biases, implying that bias correcting predictor degrades the downscaling for SWG over those regions in Winter.

Moreover SWG presents differences of biases with a large spatial variability from one season to another, for both temperature and precipitation. Hence, if the bias correction globally brings additional quality to the final SWG downscaling, the gain varies in time and space. CDFt and SWG results for the other seasons and using the IPSL GCM (instead of CNRM) display equivalent features even if spatial specificities may change (not shown). For the ANALOG method, the temperature differences are all negative in Winter (panel (c) in Fig. 1), indicating a clear gain in correcting the predictors. However, positive differences appear for the other seasons, over different regions depending on the season (not shown). Nevertheless, the positive or negative values of differences of biases are usually not as pronounced as those from SWG. Therefore, the gains or degradations brought by bias correction of the predictors in ANALOG stay relatively small for all season (not shown), especially for precipitation. Differences of biases for GAM (panel (d) in Fig. 1) are always similar to those of SWG. This was relatively expected since SWG can be seen here as a kind of stochastic version of the deterministic GAM. In other words, on average, the parameters of

the distributions modeled by GAM and SWG are equivalent but, by construction, SWG provides more variability than GAM through stochastic realizations, while GAM only provides the daily conditional expectations. This is probably the main reason explaining the pixelation in the differences of biases for SWG (panels (b) in Figs. 1 and 2), while GAM does not present this feature.

In addition to mean seasonal biases, it is also informative to look at the variability of the temperature and precipitation projections. Figs. 3 and 4 show the boxplots of seasonal variance ratios ( $VR$  in %) respectively for temperature and precipitation. For each grid-point,  $VR$  is defined as  $VR = \frac{var(S)}{var(R)} \times 100$ , where  $S$  and  $R$  correspond respectively to simulated and reference daily time series for the season of interest, i.e., respectively to the downscaled values from the (raw or corrected) GCM and those from ERA-I. The main conclusions are the same for temperature and precipitation. Whatever the season of interest, the mean  $VR$  from CDFt is not affected by the bias correction of the predictors, staying close to the “perfect” 100%  $VR$  score. Nevertheless, for precipitation, the variability of the  $VR$  values is clearly reduced around 100%, implying some gain induced by the bias correction. ANALOG does not show much difference between  $VR$  from corrected predictors or not for the precipitation variable and only slight improvements for temperature. However, the improvements are much stronger for SWG, especially in Spring and Summer for temperature (Fig. 3) and in Winter and Summer for precipitation (Fig. 4). Clear improvements (i.e.,  $RV$  closer to 100%) are also visible for GAM (in temperature) for all seasons.

Moreover, an evaluation of the gain of bias correcting the SDM predictors has also been realized in terms of extreme values of temperature and precipitation. This has been conducted through the quantification of the percentage of simulated values higher than the reference 95<sup>th</sup> percentile (hereafter referred to as  $\%_{>Q_{95}}$ ) and through the calculation of the bias (with respect to the reference time series) of the 10-year return levels (hereafter referred to as  $BRL_{10y}$ ). Both criteria provided equivalent patterns and features, similar to those given by the variance ratios. Hence,  $\%_{>Q_{95}}$  and  $BRL_{10y}$  are not shown.

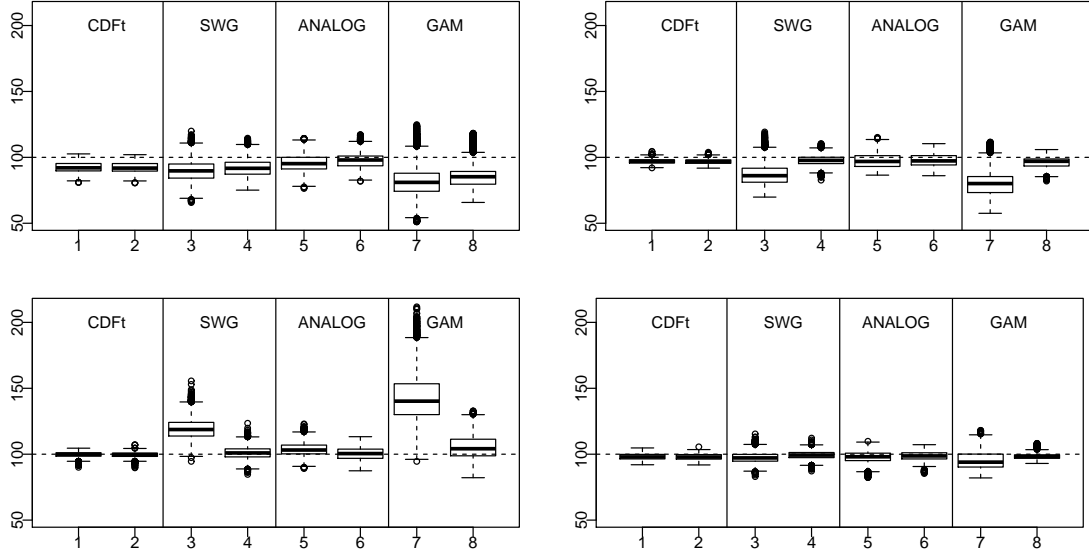


Figure 3: Boxplots of temperature Seasonal variance ratios (in %) for each SDM, from corrected or non corrected predictors. Upper left sub-figure corresponds to Winter, upper right to Spring, lower left to summer and lower right to Fall. For each SDM, the left boxplot is from non-corrected predictors while the right boxplot is from corrected predictors.




Figure 4: Same as Fig. 3 but for precipitation.

#### 4.2. Comparisons in future period context

Obviously, there are no reanalyses data to characterize future climate predictors. Therefore, the SDMs, driven by raw or corrected GCM data, cannot be compared to simulations from SDM driven by observed predictors or reanalyses. Therefore, this subsection consists in comparing, over a future time period, the raw and bias corrected GCM driven SDM outputs. This comparison is performed along two angles. First, an analysis about

the influence of bias correcting predictors on the evolutions of the mean and of the variability is performed for both temperature and precipitation. Second, the influence of such a correction on the temporal stationarity (i.e., from present to future context) is investigated, both in terms of mean climate and in terms of variability of temperature and precipitation. The future time period considered here is 2071-2100, under the RCP8.5 scenario [IPCC, 2013].

#### 4.2.1. Influences on evolutions

Figure 5 shows, on the left column, the mean winter temperature evolutions (future minus historical data) from the four SDMs driven by raw

or bias corrected CNRM predictors, as well as the map of the mean temperature evolutions as seen by the raw (i.e., not corrected and not downscaled) CNRM simulations. The right column presents

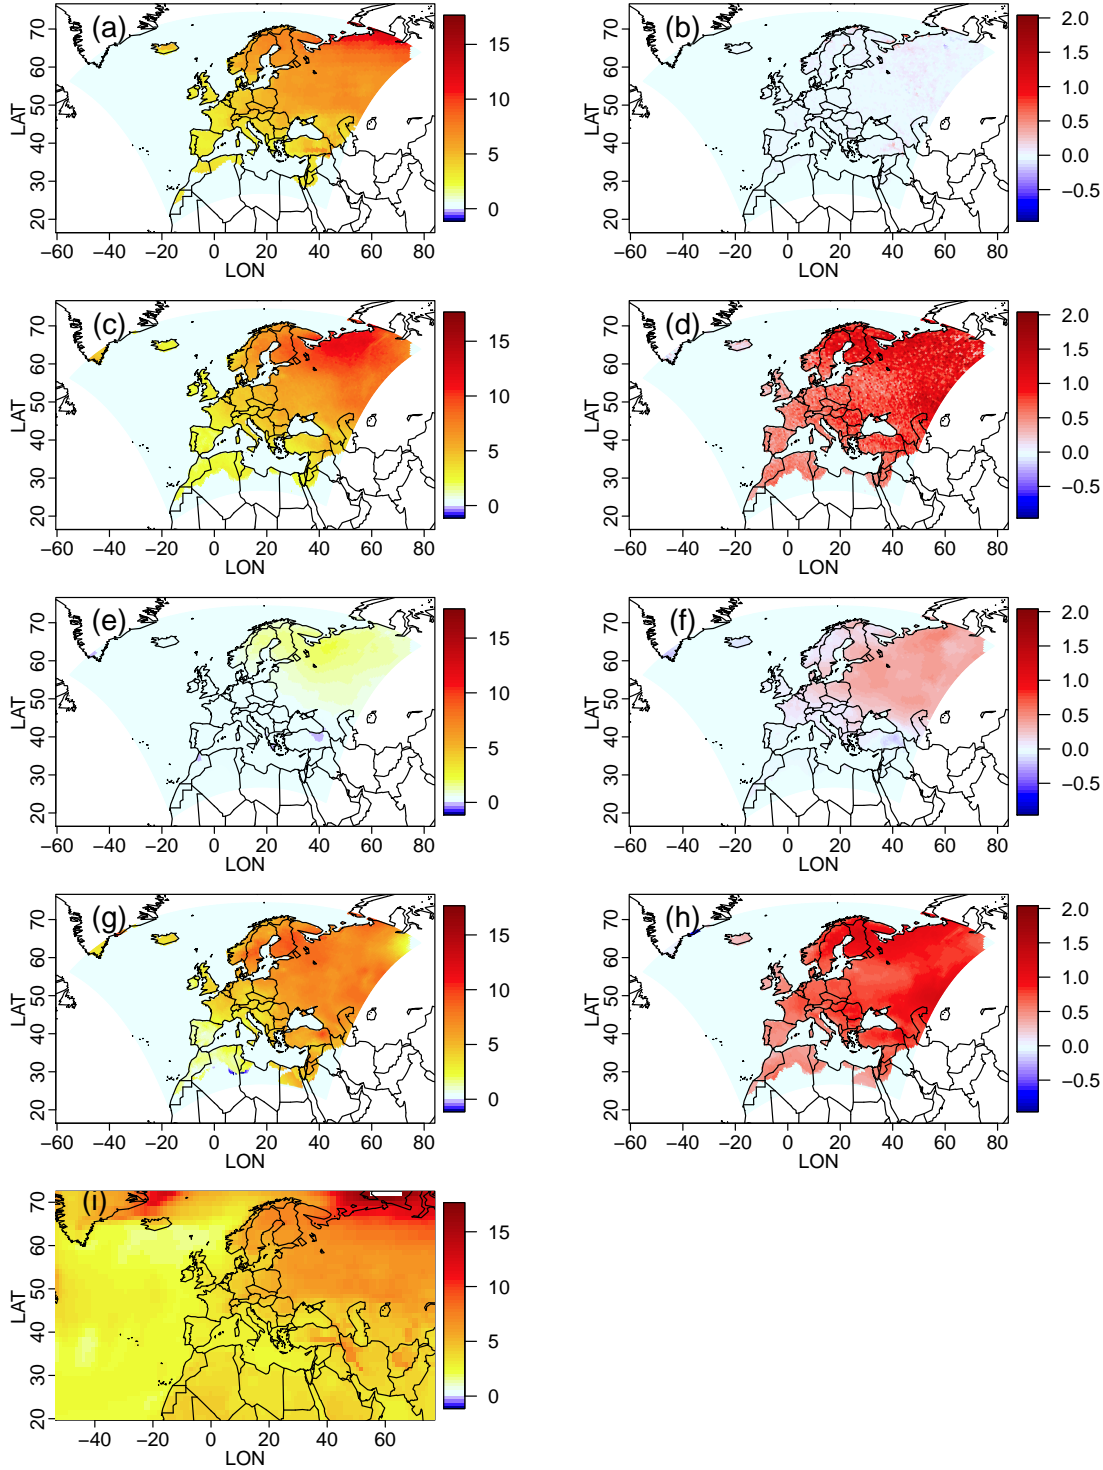


Figure 5: Left column: Maps of the mean winter temperature evolutions (future minus historical data) from the four SDMs driven by raw CNRM predictors (a, c, e, g, respectively for CDFt, SWG, ANALOG, GAM) and map of the mean winter temperature evolutions as seen by the raw and not downscaled CNRM simulations (i). Right column: Maps of the differences of mean winter temperature evolutions from 1976-2005 to 2071-2100 between BC-CNRM driven SDM simulations and raw-CNRM driven SDM simulations (i.e., evolution of SDM(BC predictors) - evolution of SDM(raw predictors)) for (b) CDFt, (d) SWG, (f) ANALOG, (h) GAM.



the maps of the differences of mean winter temperature evolutions (from 1976-2005 to 2071-2100) between BC-CNRM driven SDM simulations and raw-CNRM driven SDM simulations (i.e., evolution of SDM(BC predictors) - evolution of SDM(raw predictors)) for the four temperature SDMs. Hence, the right column allows us to visualize the influence of bias correcting the SDM predictors on the mean of the statistically down-scaled temperature simulations.

All temperature evolutions seen by the SDMs driven by raw GCM predictors (left column) are consistent with the temperature evolution from the GCM, seeing a global increase of tempera-

ture. However, if the intensity of this warming is relatively coherent (with respect to the GCM temperature) for CDFt (a), SWG (c) and GAM (g), this is not the case for ANALOG (e) that strongly underestimates it. Moreover, when looking at the differences of temperature evolutions (right column) between BC-CNRM driven SDM simulations and raw-CNRM driven SDM simulations, it is clear that bias correction of the predictors has no impact on CDFt but slightly accentuates the warming projected by ANALOG and strongly emphasizes the warming simulated by SWG and GAM.

Figure 6 shows the equivalent of Figure 5

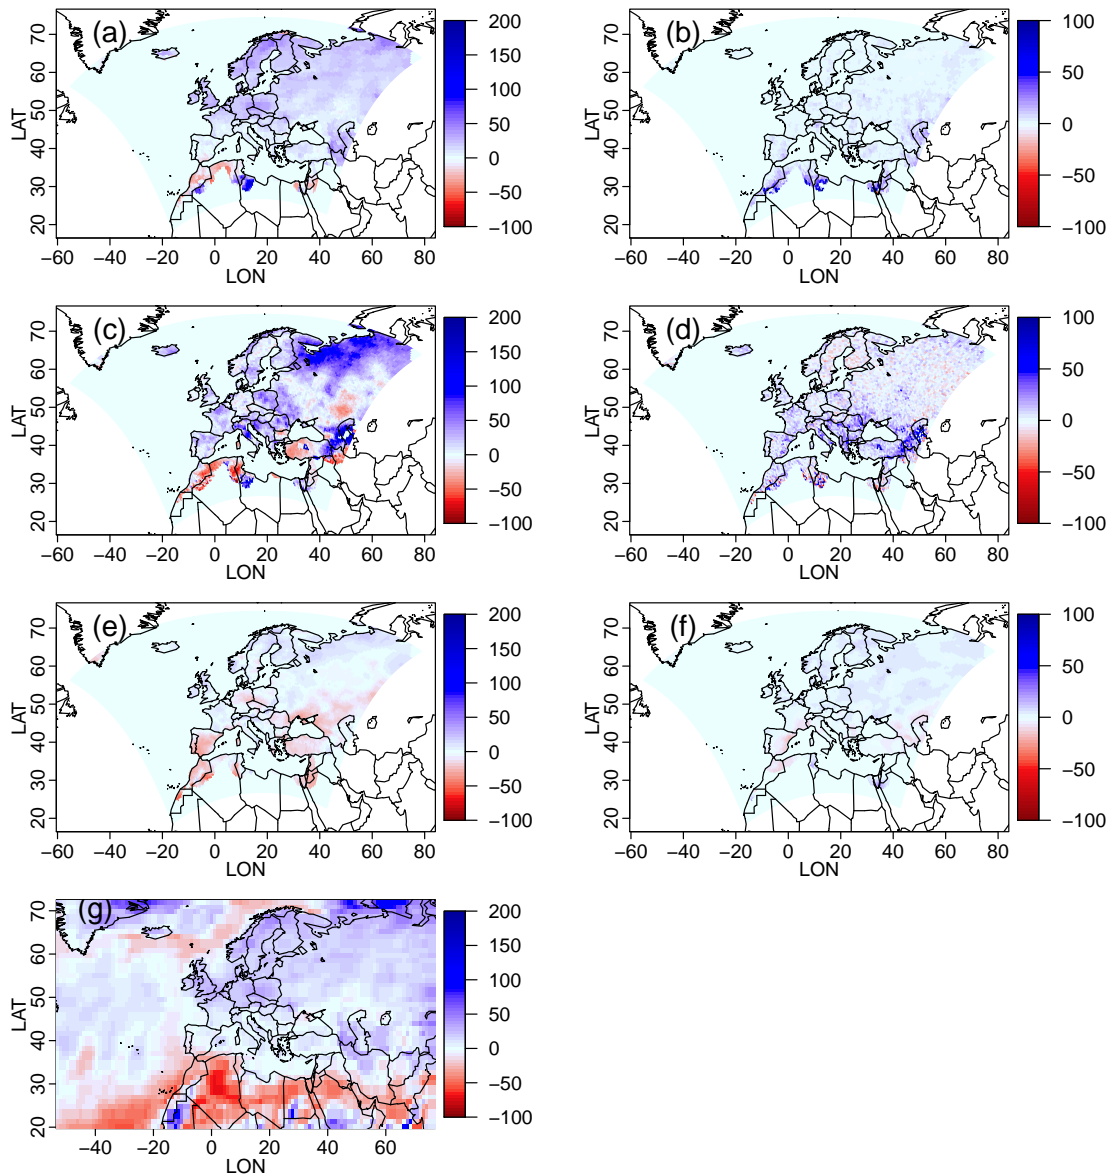


Figure 6: Same as Figure 5 but for the three precipitation SDMs: (a, b) CDFt, (c, d) SWG, (e, f) ANALOG, as well as map of the mean precipitation evolutions as seen by the raw (i.e., not corrected and not downscaled) CNRM simulations (g).



but in terms of relative evolutions (in %) for the three precipitation SDMs, as well as the map of the mean precipitation relative evolutions as seen

by the raw (i.e., not corrected and not downscaled) CNRM simulations (g).

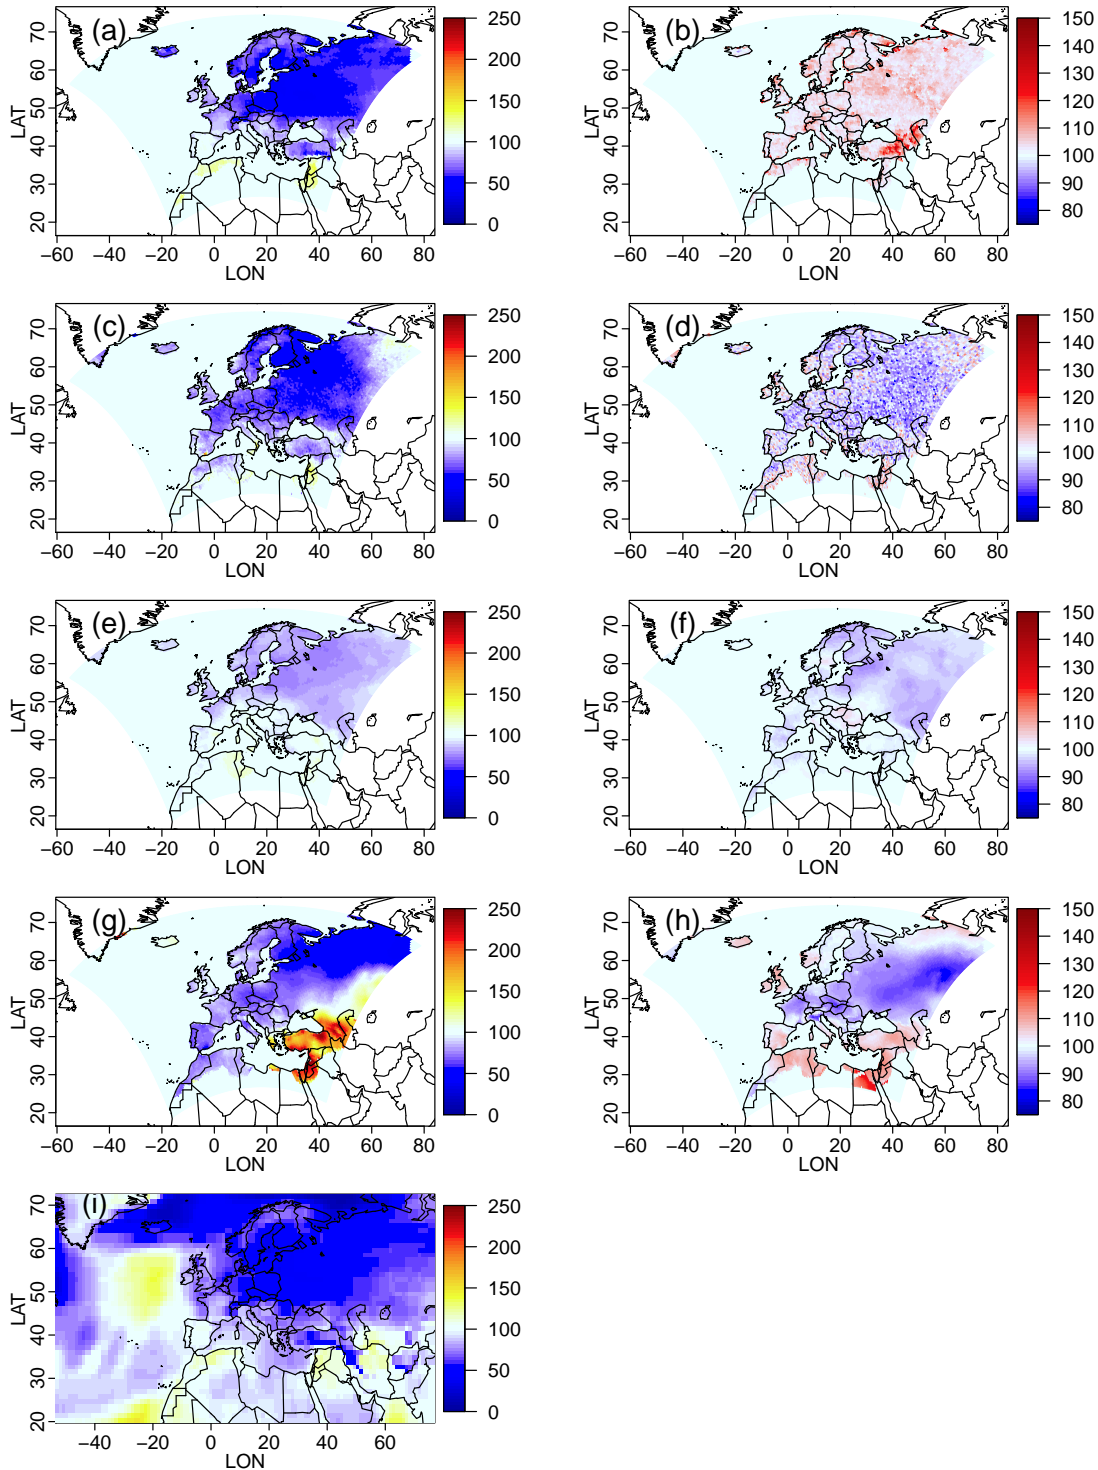


Figure 7: Left column: Maps of the evolutions (in %) of the variance of the winter daily temperatures (i.e.,  $100 \times \text{future variance} / \text{historical variance}$ ) from the four temperature SDMs (a, c, e, g, respectively for CDFt, SWG, ANALOG, GAM) driven by raw CNRM predictors, as well as map of the temperature variance evolutions as seen by the raw (i.e., not corrected and not downscaled) CNRM simulations (i). Right column: Ratios (in %) of the winter temperature variance evolutions from the BC-CNRM driven SDM simulations over those of the raw-CNRM driven SDM simulations, for (b) CDFt, (d) SWG, (f) ANALOG, (h) GAM.

As in Figure 5, the ANALOG method driven by raw predictors (e) underestimates the evolutions compared to those from the raw GCM (g). While SWG (c) projects too high mean precipitation evolutions, the CDFt model evolutions (a) are very close to that of the initial GCM. When bias correcting the predictors, the (relative) differences of evolutions (right column) are small: CDFt (b) is not much influenced by the BC except over some regions in North-Africa; ANALOG is almost not influenced at all by bias correction; SWG (d) shows the biggest influence (with an increase of mean precipitation) around the Black Sea.

Changes in variance can also be studied. Left column of Figure 7 displays the evolutions (in %) of the variance of the winter daily temperatures (i.e.,  $100 \times \text{future variance} / \text{historical variance}$ ) from the four temperature SDMs driven by raw CNRM predictors as well as map of the temperature variance evolutions as seen by the raw (i.e., not corrected and not downscaled) CNRM simulations. The right column of Figure 7 shows the ratios (in %) of the winter temperature variance evolutions from the BC-CNRM driven SDM simulations over those of the raw-CNRM driven SDM simulations, for the four temperature SDMs.

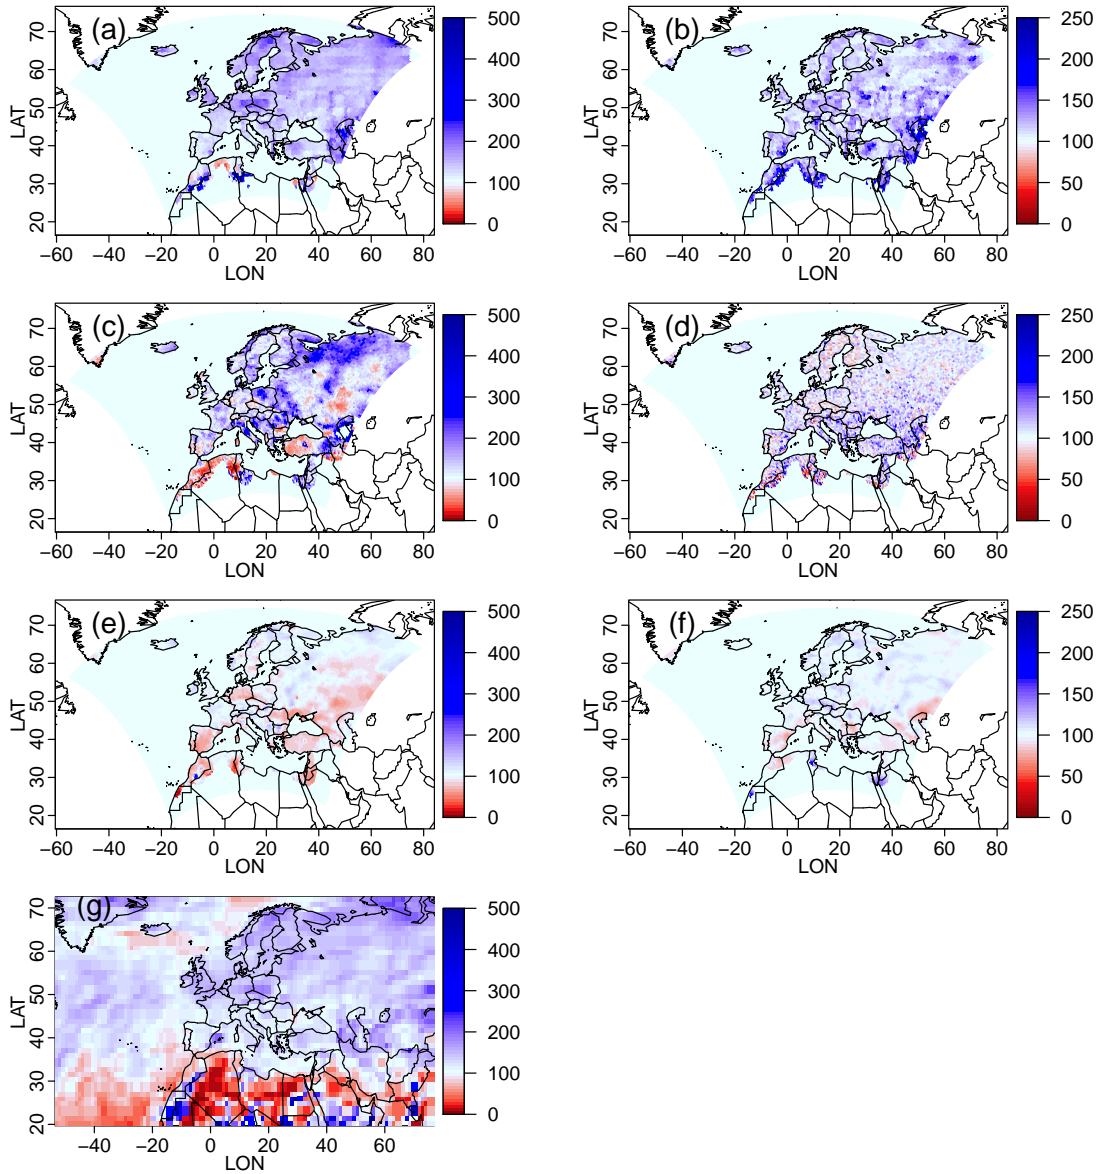


Figure 8: Same as Figure 7 but for the three precipitation SDMs: (a, b) CDFt, (c, d) SWG, (e, f) ANALOG, as well as map of the evolutions of the winter precipitation variances as seen by the raw (i.e., not corrected and not downscaled) CNRM simulations (g).

Hence, the right column allows us to visualize the influence of bias correcting the SDM predictors on the variability of the statistically downscaled temperature simulations. Results are very similar from the IPSL outputs instead of CNRM.

When driven by raw predictors, all SDMs mostly show a decrease of temperature variability in winter (except GAM (g) around the Black Sea), in agreement with the raw GCM (i). Once more, ANALOG displays the weakest intensity of change. Looking at the right column of Figure 7, the influence of the bias correction of the predictors is mainly to emphasize this decrease of temperature variability for SWG, ANALOG and GAM (resp., d, f, h), although GAM (h) can have a higher variance (due to bias correction) around the Mediterranean basin. CDFt (b) is the only SDM to see globally its BC-predictors driven temperature projections with a higher variability than its raw-predictors driven projections.

Figure 8 is the same as Figure 7 but for the three precipitation SDMs and presents also the map of the evolutions of the winter precipitation variances as seen by the raw (i.e., not corrected and not downscaled) CNRM simulations. If CDFt (a), SWG (c) – driven by the raw predictors – and the raw GCM (g) are in relative agreement with an increase of the precipitation variance, ANALOG (e) mainly displays a decrease of the daily precipitation variability. Note that, once more, SWG seems to magnify the evolutions of variance seen by the GCM while CDFt shows the evolutions the most similar to those of the GCM. Moreover, bias correcting the predictors before applying the SDMs globally increases even more the variability for CDFt (b), slightly more for SWG (d) – although some decreases with respect to raw-predictors driven SWG are visible – and does not impact the variance evolutions from the ANALOG projections (f).

#### 4.2.2. Influences on stationarity

A common question in statistical downscaling or bias correction contexts is “What is the strength of the stationarity assumption underlying those statistical models?”. In this part, this question is studied in the following way: for each variable (temperature and precipitation) and for each

statistical criterion (mean and variance), the difference between the SDM simulations driven by the corrected predictors and those driven by the raw predictors are calculated (i.e.,  $\text{SDM(BC)} - \text{SDM(raw)}$ ), not only over the historical time period (1976-2005) but also over the future time period (2071-2100). Those two differences (i.e., one for the historical period, one for the future period) can then be compared to evaluate the stationarity in time of the influence of bias correcting predictors on the SDM results.

Figure 9 shows, for each temperature SDM, the differences between the mean Winter SDM temperature simulations driven by the corrected CNRM predictors and those driven by the raw CNRM predictors (i.e.,  $\text{SDM(BC)} - \text{SDM(raw)}$ ). On the left column, the differences are calculated over the 1976-2005 period, while on the right column, it is over the 2071-2100 period. Those maps allow us to visualize the change in downscaled temperatures when the SDM is driven by bias corrected predictor, with respect to downscaled temperatures driven by raw GCM predictors.

Looking at the left column of Figure 9 (i.e., historical differences), as expected from the evaluations on the historical time period and the previous results, differences are clearly visible from one temperature SDM to another, except for SWG (c) and GAM (g) that are quite similar and with a strong spatial pattern. ANALOG (e) and CDFt (a) show respectively only small negative differences or no differences. On the right column, we can see that the differences over the 2071-2100 period are not exactly the same as in the historical period. Globally, the patterns of differences are equivalent between the two periods but the intensities are not: SWG (d) and GAM (h) still have equivalent patterns and intensities but the latter ones have been shifted by about  $+1^\circ\text{C}$ . This is the opposite for ANALOG (f) that sees a smaller but negative difference (about  $-0.5^\circ\text{C}$ .) between BC-predictor driven and raw-predictor driven models; while CDFt shows equivalent and very close to zero differences for both historical and future periods.

Figure 10 is the same as Figure 9 but for the ratio (in %) of mean precipitation from the three precipitation SDMs. This time, relative differences are very similar from the historical and future

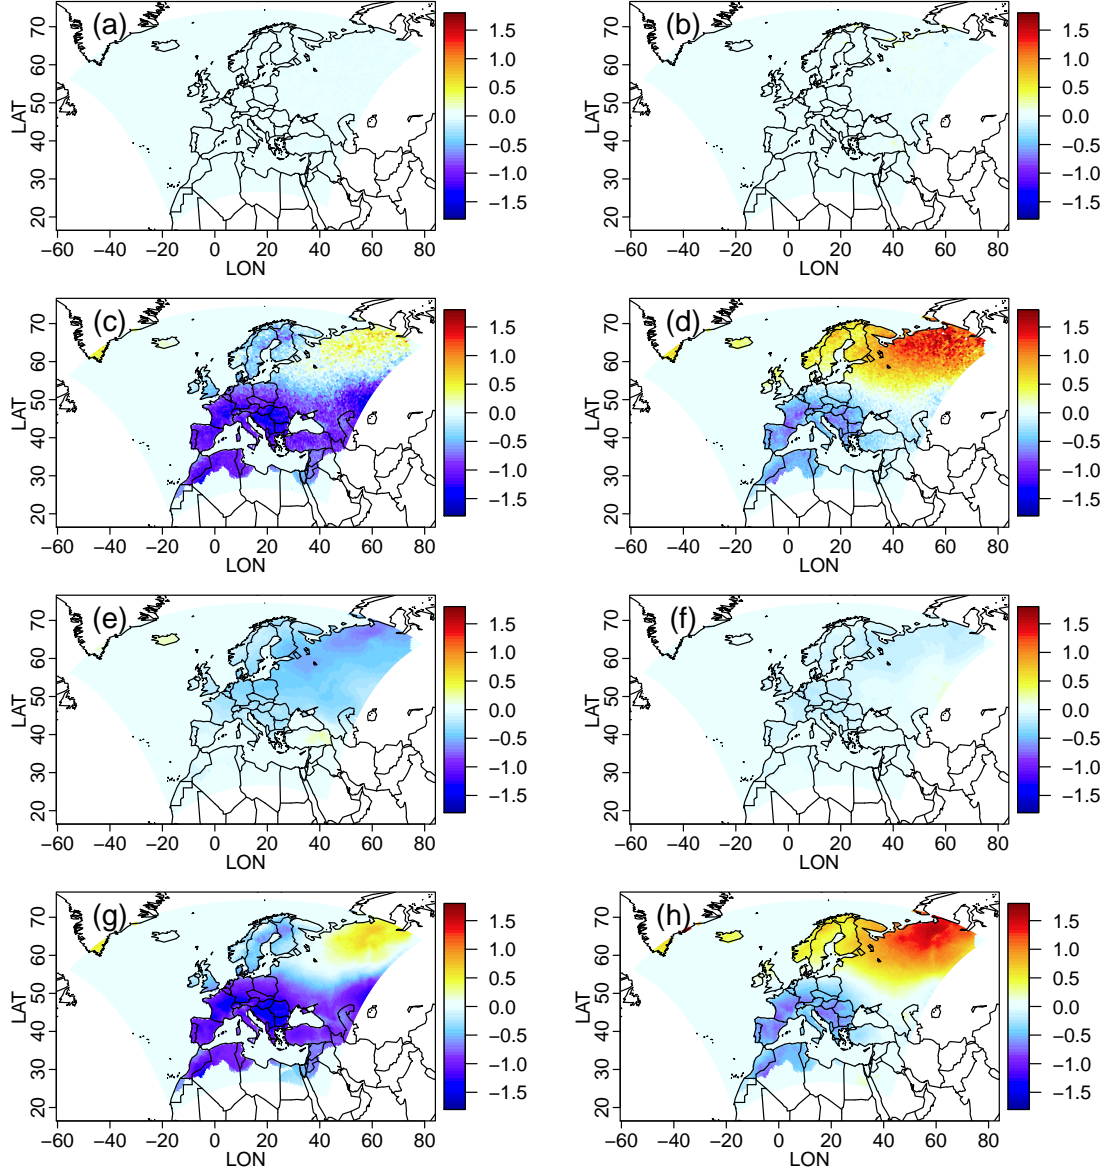


Figure 9: Differences between the mean Winter SDM temperature simulations driven by the corrected CNRM predictors and those driven by the raw CNRM predictors (i.e.,  $\text{SDM(BC)} - \text{SDM(raw)}$ ). On the left column, the differences are calculated over the 1976-2005 period, while on the right column, it is over the 2071-2100 period. (a, b) CDFt, (c, d) SWG, (e, f) ANALOG, (g, h) GAM.

time periods. CDFt (a,b) and ANALOG (e, f) show only small difference values, while SWG (c, d) has stronger intensities (both lower and higher than 100% relative differences), but the changes brought by the bias correction of the predictors in the three SDMs, for mean precipitation, are not much influenced by the considered time period.

This is not necessarily the case when looking at the stationarity of the changes brought in bias correcting the predictors in terms of variance, for both temperature and precipitation. Figure 11 shows, for the four temperature SDMs, the ratios (in %) of Winter SDM temperature variance from SDMs

applied to bias corrected or raw predictors (i.e.,  $100 \times \text{var}(\text{SDM(BC)})$  divided by  $\text{var}(\text{SDM(raw)})$ ). On the left column, the ratios and variances are calculated over the 1976-2005 period, while on the right column, it is over the 2071-2100 period. As previously, on the left column, the variance ratios are different from one SDM to another, with CDFt having the ratio the closest to 100%, indicating no changes (in terms of variance) over the historical period brought by the bias correction of the predictors. Comparing at the left and right columns of Figure 11, it is clear that the changes in winter daily temperature variances brought in correcting predictors are not stationary between



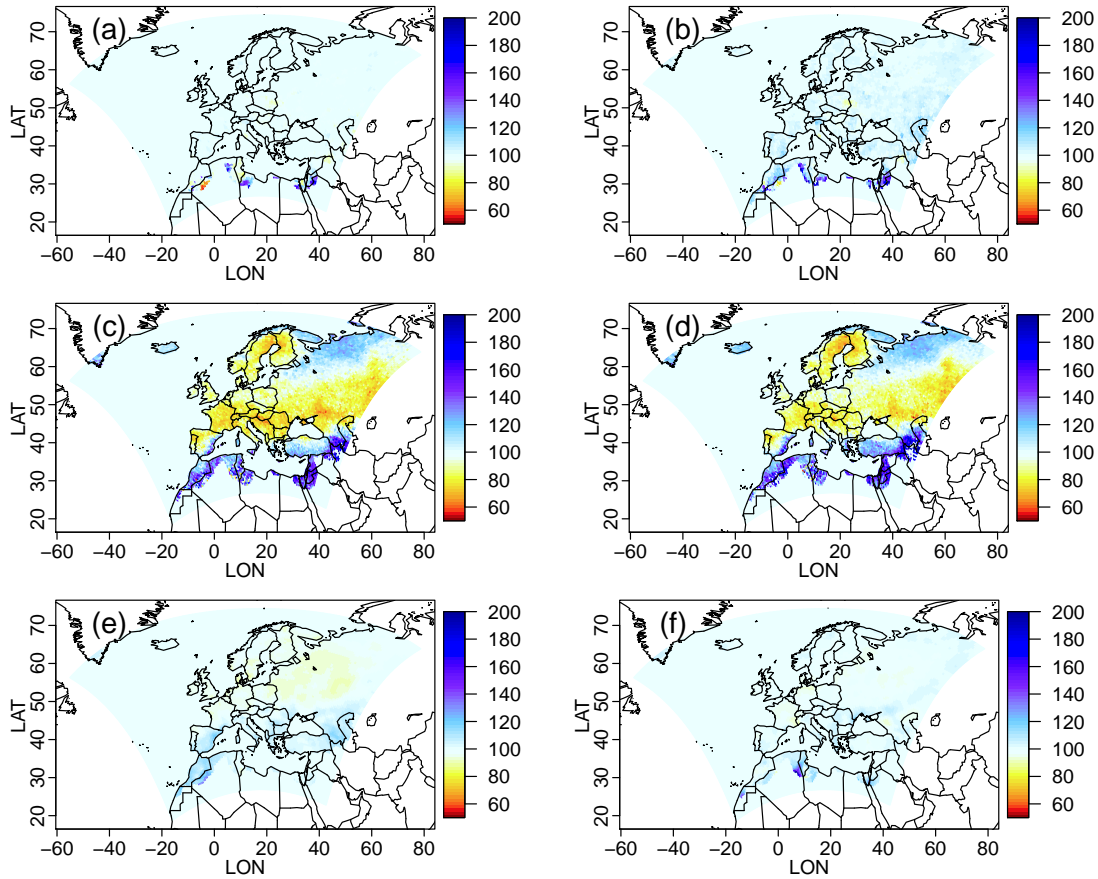


Figure 10: Same as figure 9 but for mean precipitation from the three precipitation SDMs: (a, b) CDFt, (c, d) SWG, (e, f) ANALOG.

1976-2005 and 2071-2100. Bias correcting predictors increases the variance over the future time period for CDFt (b); mostly decreases the variance in future for SWG (d) and GAM (h) and more in future than in historical period. Interestingly, if BC of the predictors slightly increases the variance of the ANALOG historical projections (e), this has no impact (on the variance) over the future time period (f), implying a non-stationary behavior.

Figure 12 shows the variance ratios maps equivalent to Figure 11 but for the precipitation ratios from three precipitation SDMs. Here, as for the relative mean precipitation in Figure 10, over the historical period, CDFt (a) and ANALOG (e) are not much influenced by the bias correction but SWG (c) is more influenced. However, comparing left (historical) and right (future) columns, if SWG (c, d) and ANALOGS (e, f) show temporal stationarity in the change of variances with very similar patterns and intensities of precipitation variance ratios, this is not the case for CDFt (a,

b) that goes from almost no impact of the bias correction of the predictors over 1976-2005 (map (a) close to 100%) to an increase of variance (ratio  $\sim 150\%$  on average) over 2071-2100.

As global conclusion, the influences brought by the BC of the SDM predictors, both in terms of mean and variance, are not always the same from one SDM to another, from one variable to another but also are not always the same over the historical period and over the end of the 21st century.

## 5. Conclusions and discussion

This study has investigated the influence of bias correcting or not the large-scale predictors used as inputs into SDM simulations of daily temperatures and precipitation. To do so, four temperature SDMs (CDFt, SWG, ANALOG, GAM) and three precipitation SDMs (CDFt, SWG, ANALOG) have been calibrated based on reanalyses and observed data over a historical time period.

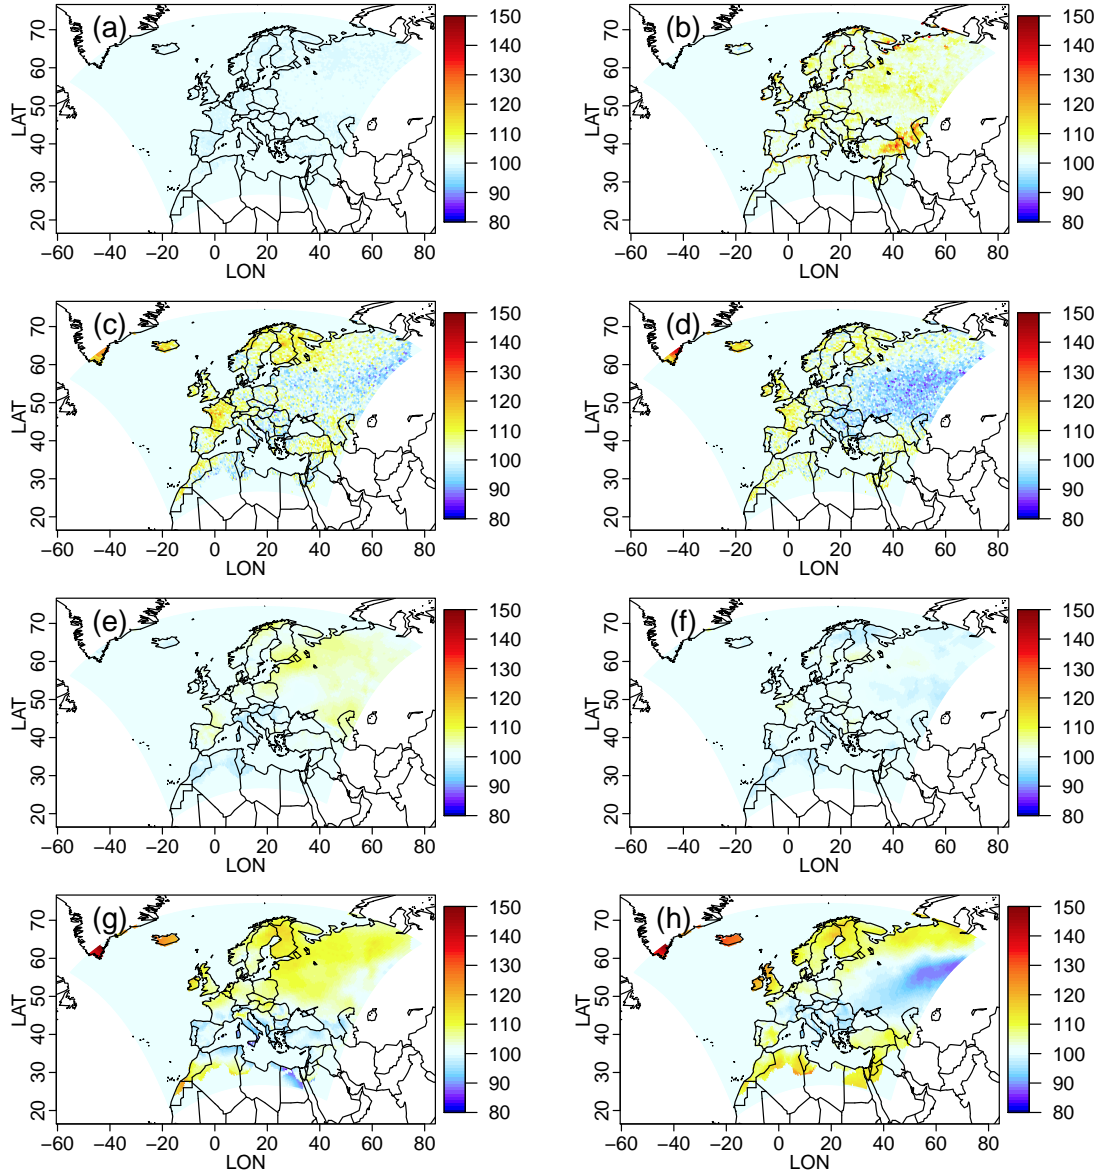


Figure 11: Ratios (in %) of Winter SDM temperature variance from SDMs applied to bias corrected or raw predictors (i.e.,  $\text{var}(\text{SDM}(\text{BC}))$  divided by  $\text{var}(\text{SDM}(\text{raw}))$ ). On the left column, the ratios and variances are calculated over the 1976-2005 period, while on the right column, it is over the 2071-2100 period: (a, b) CDFt, (c, d) SWG, (e, f) ANALOG, (g, h) GAM.

To evaluate the improvements or degradations of the quality of the statistical simulations depending on the correction or not of the predictors, the calibrated SDMs were then forced by historical predictors coming from two GCMs either corrected or not and those two types of simulations were compared to SDM simulations driven by reanalyses. The main conclusions in terms of mean and variance biases (with respect to reanalyses-driven SDMs) were that, for both temperature and precipitation, the bias correction may have some important impacts on the SDM simulations. However, the influence of the BC of the predictors is not the same from one SDM to another – e.g.,

CDFt little not influenced while SWG is much improved – with different spatial structures, and may also depend on the considered statistical properties (mean or variance). In order not to repeat the detailed results presented in sub-section 4.1, Table 1 summarizes the main conclusions of the “historical” evaluations.

The influence of bias correcting the SDM predictors on the future evolutions of some basic statistical properties of the SDM simulations has also been studied. In this climate change context, the SDMs were driven by GCM future projections in their corrected or uncorrected versions. The

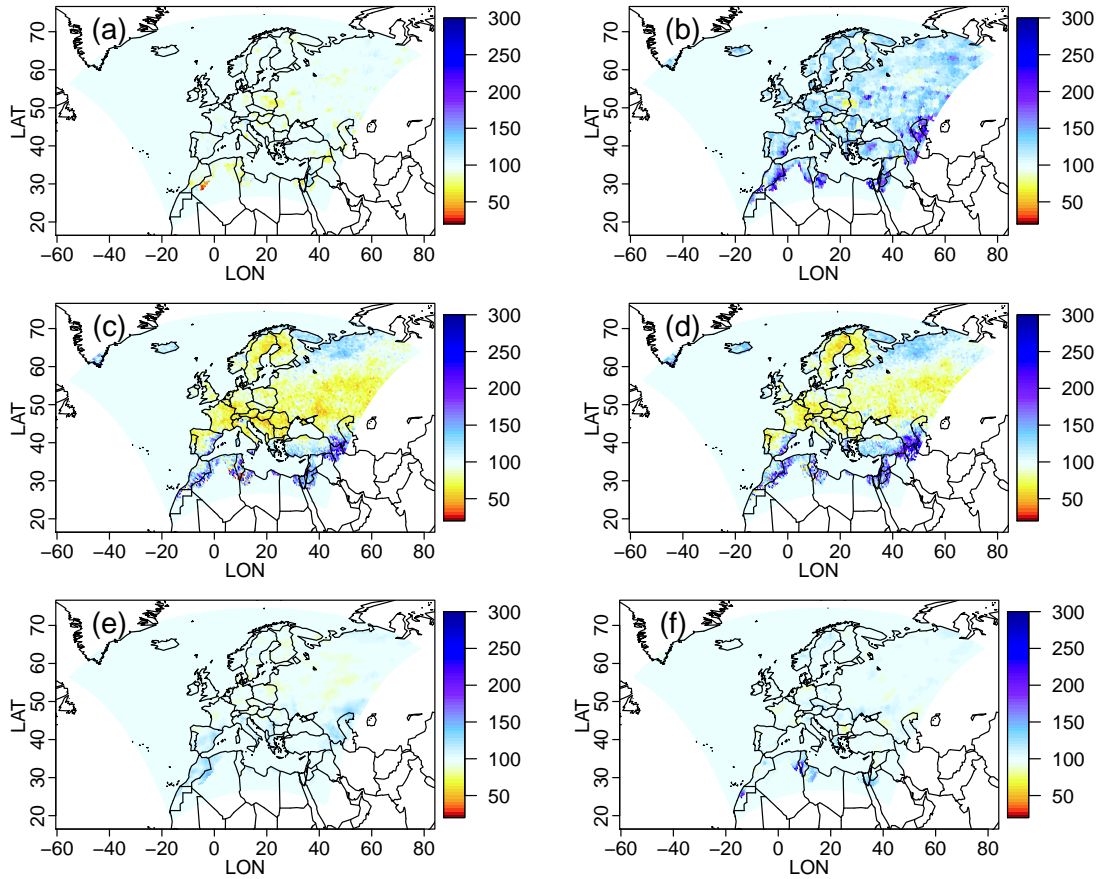


Figure 12: Same as Figure 11 but for the precipitation ratios from the three precipitation SDMs: (a, b) CDFt, (c, d) SWG, (e, f) ANALOG.

temporal mean and variance evolutions of the bias corrected predictors-driven SDMs precipitation and temperature simulations were compared to those of the raw predictors-driven SDMs, as well as to those of the raw GCM. Globally, raw predictors-driven CDFt, SWG and GAM (for temperature only) evolutions are more or less in agreement with raw GCM evolutions – although some spatial,

variable-, or criterion-related specificities were visible – while raw predictors-driven ANALOG had a much weaker intensity of evolutions. The influence of the bias correction on those SDM evolutions depends again on the SDM, the considered variable and the statistical criterion. Table 2 provides a synthetic overview of the main conclusions seen from sub-section 4.2.1.

SDMs	Mean Temp.	Var. Temp	Rel. mean PR	Var. PR
CDFt	Not influenced	Not influenced	Not influenced	Not influenced (range reduced)
SWG	Influenced (improved)	Influenced (improved)	Influenced (improved)	Influenced (improved)
ANALOG	Moderately influenced (improved)	Not influenced	Moderately influenced (improved)	Not influenced
GAM	Influenced (improved)	Influenced (improved)	NA	NA

Table 1: Main conclusions about the influence of the bias correction of the GCM predictors on the mean and variance “historical” biases of the SDM simulations with respect to ERA-I-driven SDM simulations. See sub-section 4.1 for details.

SDMs	Mean Temp.	Var. Temp	Rel. mean PR	Var. PR
CDFt	No influence	Influence (increased var.)	No influence	Strong influence (increased var.)
SWG	Influence (increased warming)	Influence (decreased var.)	Moderate influence (increased PR)	Moderate influence (mostly increased var.)
ANALOG	Moderate influence (increased warming)	Moderate influence (decreased var.)	No influence	Weak influence (both signs)
GAM	Influence (increased warming)	Strong influence (both signs)	NA	NA

Table 2: Main conclusions about the influence of the bias correction of the predictors on the mean and variance evolutions of the SDM simulations. See sub-section 4.2.1 for details.

Finally, for the two variables, the temporal stationarity of the changes brought by the BC of the predictors has been investigated in terms of means and variances. Those changes (i.e., differences or ratios) have been computed over the historical (1976-2005) and future (2071-2100) time periods and compared to assess the (non-) stationarity. Once more, the results were versatile, depending on the considered variable, criterion and SDM but some potentially strong non-stationarities were found. Table 3 gives a short summary of the main findings of sub-section 4.2.2.

Hence, this study brought some useful information to use and interpret properly the simulations provided by statistical downscaling models, either

with bias corrected or with uncorrected predictors from GCM as inputs.

The present work can obviously be extended further in many manners. For example, only one BC method has been employed here (CDFt). However, some preliminary analyses have also been performed with a classical “quantile-quantile” BC method, indicating that the main conclusions are robust (not shown). Nevertheless, increasing the number of BC models to realize the same analyses as done in this paper could be necessary to have a more global overview of the impact of bias correction in such a context.

In the same type of ideas, using more GCMs would help generalizing the conclusions of such a

SDMs	Mean Temp.	Var. Temp	Rel. mean PR	Var. PR
CDFt	Stationary	Non-stationary (increased changes)	Stationary	Non-stationary (increased changes)
SWG	Non-stationary (increased changes)	Moderately non-stat. (some regions)	Stationary	Stationary
ANALOG	Moderately non-stat. (decreased changes)	Non-stationary (decreased changes)	Stationary	Stationary
GAM	Non-stationary (increased changes)	Moderately non-stat. (some regions)	NA	NA

Table 3: Main conclusions concerning the temporal stationarity of changes – in means and variances – brought by the bias correction of the predictors for the SDM simulations. See sub-section 4.2.2 for details.

study. Of course, the same analyses could also be carried out with RCMs instead of GCMs to understand the influence of the resolution (GCM vs. RCM as predictors) or the influence of different coupling in RCM on the final statistically

downscaled results (e.g., ocean-atmosphere coupled RCM vs. stand-alone atmosphere RCM).

Moreover, this study and the associated analyses are not restricted to SDMs and can certainly be performed with (or in including) RCMs instead of (or in addition to) SDMs. Some attempts have



been made in this direction for example by Collette et al., 2012 or Bruyère et al., 2014, evaluating RCM runs forced by bias corrected GCM data.

Finally, it is important to keep in mind that spatial or intervariable dependencies were not accounted for, neither in the BC method nor in the SDMs tested in this study. The introduction of such specificities may have consequences on the

results and conclusions brought by the present analyses. This remains therefore an important perspective of future work.

**Acknowledgments** This work has been partially supported by the ANR-project StaRMIP (grant ANR-12-JS06-0005-01), the CLIP-C project (FP7 grant # 607418), the ANR-project REMEMBER (grant agreement ANR- 12-SENV-0001-01), the EXTREMOSCOPE project (supported by the French Ministry of Ecology) and the LABEX-IPSL project (grant ANR-10-LABX-18-01). All computations have been made in R.

### 3. Perspectives

Les perspectives des travaux menés dans ce chapitre s'incrivent plutôt dans une volonté de les compléter. En effet, ce chapitre apporte des informations importantes pour une meilleure utilisation et interprétation des simulations issues des SDMs forcés par les GCMs. Elles demandent néanmoins à être complétées.

Tout d'abord, une seule méthode de correction de biais a été utilisée. L'utilisation de plusieurs méthodes de correction nous aiderait à mieux appréhender et interpréter les différentes influences de la correction. Dans la même idée, la prise en compte de GCMs supplémentaires permettrait une généralisation des conclusions de cette étude.

De plus, des analyses similaires peuvent être menées en remplaçant des prédicteurs issus des RCMs aux lieux des GCMs pour comprendre l'influence de la résolution ou des différents couplages des RCMs sur les sorties des modèles statistiques (e.g., un RCM couplé océan-atmosphère par rapport à un RCM uniquement atmosphérique).

Par ailleurs, cette étude ne se restreint pas uniquement aux SDMs et peut être réalisée en incluant des RCMs aux modèles de downscaling utilisés. Quelques études ont évalué des sorties de RCMs forcées par des GCM corrigés [COLETTE et al., 2012 ; BRUYÈRE et al., 2014]. Cette approche reste encore à être approfondie.

Enfin, il est important de souligner que la dépendance intervariable n'est pas prise en compte, que ce soit dans la procédure de correction de biais ou dans les SDMs évalués dans cette étude. La considération de telles dépendances modifiera sans doute les résultats et conclusions établies dans ce chapitre. Ceci représente une perspective de travail importante pour les travaux à venir.

## 4. Synthèse des résultats

Pour tester l'influence des biais des GCMs sur les modèles de régionalisation statistique, un cadre d'intercomparaison a été adopté. Quatre modèles de températures et trois modèles de précipitations ont été testés. Les prédicteurs ont été sélectionnés dans les réanalyses ERA-I et les GCMs IPSL-CM5-MR et CNRM-CM5 et les observations sont issues de la base de données E-OBS.

À partir de cela, nous avons mis en place une procédure de correction de biais des données GCMs en utilisant ERA-I comme référence. Ensuite, les SDMs calibrés à partir des observations et de ERA-I ont été forcés par ERA-I et les GCMs bruts et corrigés sur la période historique et future pour obtenir des simulations.

Trois tests ont été mis en place pour évaluer les apports et les impacts de la correction de biais sur ces simulations :

- un test en climat CTRL : pour déterminer l'influence de la correction de biais sur les simulations issues des SDMs ;
- un test d'évolution : pour déterminer l'influence de la correction de biais sur l'évolution future des simulations issues des SDMs ;
- un test de stationnarité : pour évaluer la stationnarité temporelle des changements apportés par la correction de biais entre la période historique et future.

Les principaux résultats montrent une influence indéniable de la correction des biais des GCMs sur les sorties des SDMs. Les conséquences des biais dépendent toutefois du modèle et de la variable d'intérêt et sont hétérogènes du point de vue spatial et en intensité.

## Références Bibliographiques du Chapitre III

- BARNSTON, Anthony G. & LIVEZEY, Robert E. [1987]. "Classification, Seasonality and Persistence of Low-Frequency Atmospheric Circulation Patterns". *Monthly Weather Review*. Vol. 115. no. 6, p. 1083–1126.
- BRUYÈRE, C. L., DONE, J. M., HOLLANDA, G. J. & FREDRICK, S. [2014]. "Bias corrections of global models for regional climate simulations of high-impact weather". *Climate Dynamics*. Vol. 43, p. 1847–1856.
- BUISHAND, T. A., SHABALOVA, M. V. & BRANDSMA, T. [2004]. "On the Choice of the Temporal Aggregation Level for Statistical Downscaling of Precipitation". *Journal of Climate*. Vol. 17. no. 9, p. 1816–1827.
- CHANDLER, R. E. & WHEATER, H. S. [2002]. "Analysis of rainfall variability using generalized linear models : A case study from the west of Ireland". *Water Resour. Res.*. Vol. 38(10), p. 1192.
- CHARLES, S. P., BARI, M. A., KITSIOS, A. & BATES, B. C. [2007]. "Effect of GCM bias on downscaled precipitation and runoff projections for the Serpentine catchment, Western Australia". *International Journal of Climatology*. Vol. 27. no. 12, p. 1673–1690.
- CHARLES, Stephen P., BATES, Bryson C., WHETTON, Peter H. & HUGHES, James P. [1999]. "Validation of downscaling models for changed climate conditions : case study of southwestern Australia". *Climate Research*. Vol. 12. no. 1, p. 1–14.
- CHARLES, Stephen P., BATES, Bryson C., SMITH, Ian N. & HUGHES, James P. [2004]. "Statistical downscaling of daily precipitation from observed and modelled atmospheric fields". *Hydrological Processes*. Vol. 18. no. 8, p. 1373–1394.
- CHRISTENSEN, J.H., BOBERG, F., CHRISTENSEN, O.B. & LUCAS-PICHER, P. [2008]. "On the need for bias correction of regional climate change projections of temperature and precipitation". *Geophysical Research Letters*. Vol. 35. no. 20.
- COLETTE, A., VAUTARD, R. & VRAC, M. [2012]. "Regional climate downscaling with prior statistical correction of the global climate forcing". *Geophysical Research Letters*. Vol. 39, L13707, doi :10.1029/2012GL052258.
- DEE, D. P., UPPALA, S. M., SIMMONS, A. J., BERRISFORD, P., POLI, P., KOBAYASHI, S., ANDRAE, U., BALMASEDA, M. A., BALSAMO, G., BAUER, P., BECHTOLD, P., BELJAARS, A. C. M., BERG, L. van de, BIDLOT, J., BORMANN, N., DELSOL, C., DRAGANI, R., FUENTES, M., GEER, A. J., HAIMBERGER, L., HEALY, S. B., HERSBACH, H., HÓLM, E. V., ISAKSEN, I., KÄLLBERG, P., KÖHLER, M., MATRICARDI, M., McNALLY, A. P., MONGE-SANZ, B. M., MORCRETTE, J.-J., PARK, B.-K., PEUBEY, C., ROSNAY, P. de, TAVOLATO, C., THÉPAUT, J.-N. & VITART, F. [2011]. "The ERA-Interim reanalysis : configuration and performance of the data assimilation system". *Quarterly Journal of the Royal Meteorological Society*. Vol. 137. no. 656, p. 553–597.
- DUFRESNE, J.-L., FOJOLS, M.-A., DENVIL, S., CAUBEL, A., MARTI, O., AUMONT, O., BALKANSKI, Y., BEKKI, S., BELLENGER, H., BENSHILA, R., BONY, S., BOPP, L., BRACONNOT, P., BROCKMANN, P., CADULE, P., CHERUY, F., CODRON, F., COZIC, A., CUGNET, D., NOBLET, N. de, DUVEL, J.-P., ETHÉ, C., FAIRHEAD, L., FICHEFET, T., FLAVONI, S., FRIEDLINGSTEIN, P., GRANDPEIX, J.-Y., GUEZ, L., GUILYARDI, E., HAUGLUSTAINE, D., HOURDIN, F., IDELKADI, A., GHATTAS, J., JOUSSAUME, S., KAGEYAMA, M., KRINNER, G., LABETOULLE, S., LAHELLEC, A., LEFEBVRE, M.-P., LEFEBVRE, F., LEVY, C., LI, Z. X., LLOYD, J., LOTT, F., MADEC, G., MANCIP, M., MARCHAND, M., MASSON, S., MEURDESIOIF, Y., MIGNOT, J., MUSAT, I., PAROUTY, S., POLCHER, J., RIO, C., SCHULZ, M., SWINGEDOUW, D., SZOPA, S., TALANDIER, C., TERRAY, P., VIOVY, N. & VUICHARD, N. [2013]. "Climate change projections using the IPSL-CM5 Earth System Model : from CMIP3 to CMIP5". *Clim. Dyn.*. Vol. 40, p. 2123–2165.
- FEALY, Rowan & SWEENEY, John [2007]. "Statistical downscaling of precipitation for a selection of sites in Ireland employing a generalised linear modelling approach". *International Journal of Climatology*. Vol. 27. no. 15, p. 2083–2094.
- FRÍAS, M. D., ZORITA, E., FERNÁNDEZ, J. & RODRÍGUEZ-PUEBLA, C. [2006]. "Testing statistical downscaling methods in simulated climates". *Geophysical Research Letters*. Vol. 33. no. 19.
- GAITAN, Carlos F., HSIEH, William W. & CANNON, Alex J. [2014]. "Comparison of statistically downscaled precipitation in terms of future climate indices and daily variability for southern Ontario and Quebec, Canada". *Climate Dynamics*. P. 1–17.
- GRENIER, Patrick, PARENT, Annie-Claude, HUARD, David, ANCTIL, François & CHAUMONT, Diane [2013]. "An Assessment of Six Dissimilarity Metrics for Climate Analogs". *Journal of Applied Meteorology and Climatology*. Vol. 52. no. 4, p. 733–752.
- GROUILLET, B., RUELLAND, D., VAITTINADA AYAR, P. & VRAC, M. [2015]. "Sensitivity analysis of runoff modeling to statistical downscaling models in the western Mediterranean". *Hydrology and Earth System Sciences Discussions*. Vol. 12. no. 10, p. 10067–10108.
- GUDMUNDSSON, L., BREMNES, J. B., HAUGEN, J. E. & ENGEN-SKAUGEN, T. [2012]. "Technical Note : Downscaling RCM precipitation to the station scale using statistical transformations - a comparison of methods". *Hydrology and Earth System Sciences*. Vol. 16. no. 9, p. 3383–3390.

- HADDAD, Z.S. & ROSENFELD, D. [1997]. “Optimality of empirical z-r relations”. *Q. J. R. Meteorol. Soc.*. Vol. 123, p. 1283–1293.
- HAGEMANN, Stefan, CHEN, Cui, HAERTER, Jan O., HEINKE, Jens, GERTEN, Dieter & PIANI, Claudio [2011]. “Impact of a Statistical Bias Correction on the Projected Hydrological Changes Obtained from Three GCMs and Two Hydrology Models”. *Journal of Hydrometeorology*. Vol. 12. no. 4, p. 556–578.
- HASTIE, T. & TIBSHIRANI, R. [1990]. “Generalized Additive Models”. Monographs on statistics and applied probability. Chapman & Hall.
- HAYLOCK, M. R., HOFSTRA, N., KLEIN TANK, A. M. G., KLOK, E. J., JONES, P. D. & NEW, M. [2008]. “A European daily high-resolution gridded data set of surface temperature and precipitation for 1950–2006”. *Journal of Geophysical Research : Atmospheres*. Vol. 113. no. D20.
- HAYLOCK, Malcolm R., CAWLEY, Gavin C., HARPHAM, Colin, WILBY, Rob L. & GOODESS, Clare M. [2006]. “Downscaling heavy precipitation over the United Kingdom : a comparison of dynamical and statistical methods and their future scenarios”. *International Journal of Climatology*. Vol. 26. no. 10, p. 1397–1415.
- HEWITSON, BC & CRANE, RG [1996]. “Climate downscaling : techniques and application”. *Climate Research*. Vol. 7. no. 2, p. 85–95.
- HUTH, Radan [1999]. “Statistical downscaling in central Europe : evaluation of methods and potential predictors”. *Climate Research*. Vol. 13. no. 2, p. 91–101.
- IPCC [2013]. “Climate Change 2013 : The Physical Science Basis. Contribution of Working Group I to the Fifth Assessment Report of the Intergovernmental Panel on Climate Change”. Cambridge University Press, Cambridge, United Kingdom & New York, NY, USA : Stocker, T.F., D. Qin, G.-K. Plattner, M. Tignor, S.K. Allen, J. Boschung, A. Nauels, Y. Xia, V. Bex and P.M. Midgley (eds.)
- KALNAY, E., KANAMITSU, M., KISTLER, R., COLLINS, W., DEAVEN, D., GANDIN, L., IREDELL, M., SAHA, S., WHITE, G., WOOLLEN, J., ZHU, Y., CHELLIAH, M., EBISUZAKI, W., W. HIGGINS, JANOWIAK, J., MO, K. C., ROPELEWSKI, C., WANG, J., LEETMAA, A., REYNOLDS, R., JENNE, R. & JOSEPH, D. [1996]. “The NCEP/NCAR 40-Year Reanalysis Project”. *Bulletin of the American Meteorological Society*. Vol. 77 (3), p. 437–471.
- KLOK, E.J. & KLEIN TANK, A.M.G. [2009]. “Updated and extended European dataset of daily climate observations”. *International Journal of Climatology*. Vol. 29. no. 8, p. 1182–1191.
- LAPRISE, R., ELÍA, R. de, CAYA, D., BINER, S., LUCAS-PICHER, P., DIACONESCU, E., LEDUC, M., ALEXANDRU, A. & SEPAROVIC, L. [2008]. “Challenging some tenets of Regional Climate Modelling”. *Meteorology and Atmospheric Physics*. Vol. 100. no. 1-4, p. 3–22.
- LEVAVASSEUR, G., VRAC, M., ROCHE, D. M., PAILLARD, D., MARTIN, A. & VANDENBERGHE, J. [2011]. “Present and LGM permafrost from climate simulations : contribution of statistical downscaling”. *Climate of the Past*. Vol. 7. no. 4, p. 1225–1246.
- MARAUN, D., WETTERHALL, F., IRESON, A. M., CHANDLER, R. E., KENDON, E. J., WIDMANN, M., BRIENEN, S., RUST, H. W., SAUTER, T., THEMESSEL, M., VENEMA, V. K. C., CHUN, K. P., GOODESS, C. M., JONES, R. G., ONOF, C., VRAC, M. & THIELE-EICH, I. [2010]. “Precipitation downscaling under climate change : Recent developments to bridge the gap between dynamical models and the end user”. *Reviews of Geophysics*. Vol. 48. no. 3.
- MARTI, O., BRACONNOT, P., DUFRESNE, J.L., BELLIER, J., R., Benshila, BONY, S., BROCKMANN, P., CADULE, P., CAUBEL, A., CODRON, F., NOBLET, N. de, DENVIL, S., FAIRHEAD, L., FICHEFET, T., FOJOLS, M., FRIEDLINGSTEIN, P., GOOSSE, H., GRANDPEIX, J., GUILYARDI, E., HOURDIN, F., IDELKADI, A., KAGEYAMA, M., KRINNER, G., LÉVY, C., MADEC, G., MIGNOT, J., MUSAT, I., SWINGEDOUW, D. & TALANDIER, C. [2010]. “Key features of the IPSL ocean atmosphere model and its sensitivity to atmospheric resolution”. *Climate Dynamics*. Vol. 34, p. 1–26.
- MEEHL, G.A. et al. [2007]. “Global Climate Projections. In : Climate Change 2007 : The physical basis. Contribution of Working Group 1 to the fourth Assessment report of the Intergovernmental Panel on Climate Change”. Cambridge, UK : Solomon et al., Cambridge University Press.
- MICHELANGELI, P.-A., VRAC, M. & LOUKOS, H. [2009]. “Probabilistic downscaling approaches : Application to wind cumulative distribution functions”. *Geophysical Research Letters*. Vol. 36. no. 11.
- NASH, J.E. & SUTCLIFFE, J.V. [1970]. “River flow forecasting through conceptual models part I — A discussion of principles”. *Journal of Hydrology*. Vol. 10. no. 3, p. 282–290.
- PERRIN, Charles, MICHEL, Claude & ANDRÉASSIAN, Vazken [2003]. “Improvement of a parsimonious model for streamflow simulation”. *Journal of Hydrology*. Vol. 279. no. 1–4, p. 275–289.
- ROBERTSON, A.W., KIRSHNER, S. & SMYTH, P. [2004]. “Downscaling of daily rainfall occurrence over northeast Brazil using a hidden Markov model”. *J. Clim.*. Vol. 17, p. 4407–4424.
- RUMMUKAINEN, Markku [2010]. “State-of-the-art with regional climate models”. *Wiley Interdisciplinary Reviews : Climate Change*. Vol. 1. no. 1, p. 82–96.

- SALAMEH, T., DROBINSKI, P., VRAC, M. & NAVEAU, P. [2009]. “Statistical downscaling of near-surface wind over complex terrain in southern France”. *Meteorology and Atmospheric Physics*. Vol. 103. no. 1-4, p. 253–265.
- SAURRAL, Ramiro I., MONTROULL, Natalia B. & CAMILLONI, Inés A. [2013]. “Development of statistically unbiased twenty-first century hydrology scenarios over La Plata Basin”. *International Journal of River Basin Management*. Vol. 11. no. 4, p. 329–343.
- SCHMIDLI, J., GOODESS, C. M., FREI, C., HAYLOCK, M. R., HUNDECHA, Y., RIBALAYGUA, J. & SCHMITH, T. [2007]. “Statistical and dynamical downscaling of precipitation : An evaluation and comparison of scenarios for the European Alps”. *Journal of Geophysical Research : Atmospheres*. Vol. 112. no. D4.
- VAITTINADA AYAR, Pradeebane, VRAC, Mathieu, BASTIN, Sophie, CARREAU, Julie, DÉQUÉ, Michel & GALLARDO, Clemente [2015]. “Intercomparison of statistical and dynamical downscaling models under the EURO- and MED-CORDEX initiative framework : present climate evaluations”. *Climate Dynamics*. P. 1–29.
- VAUTARD, Robert & YIOU, Pascal [2009]. “Control of recent European surface climate change by atmospheric flow”. *Geophysical Research Letters*. Vol. 36. no. 22.
- VOLDOIRE, A., SANCHEZ-GOMEZ, E., MÉLIA, D. Salas y, DECHARME, B., CASSOU, C., SÉNÉSI, S., VALCKE, S., BEAU, I., ALIAS, A., CHEVALLIER, M., DÉQUÉ, M., DESHAYES, J., DOUVILLE, H., FERNANDEZ, E., MADEC, G., E. MAISONNAVE AND, M.-P. Moine, PLANTON, S., D.SAINT-MARTIN, SZOPA, S., TYTECA, S., ALKAMA, R., BELAMARI, S., BRAUN, A., COQUART, L. & CHAUVIN, F. [2013]. “The CNRM-CM5.1 global climate model : description and basic evaluation”. *Clim. Dyn.*. Vol. 40. no. 9, p. 2091–2121.
- VRAC, M., STEIN, M. L., HAYHOE, K. & LIANG, X.-Z. [2007a]. “A general method for validating statistical downscaling methods under future climate change”. *Geophysical Research Letters*. Vol. 34. no. 18.
- VRAC, M., MARBAIX, P., PAILLARD, D. & NAVEAU, P. [2007c]. “Non-linear statistical downscaling of present and LGM precipitation and temperatures over Europe”. *Climate of the Past*. Vol. 3. no. 4, p. 669–682.
- VRAC, M., STEIN, M. L. & HAYHOE, K. [2007d]. “Statistical downscaling of precipitation through nonhomogeneous stochastic weather typing”. *Climate Research*. Vol. 34. no. 3, p. 169–184.
- VRAC, M., DROBINSKI, P., MERLO, A., HERRMANN, M., LAVAYSSE, C., LI, L. & SOMOT, S. [2012]. “Dynamical and statistical downscaling of the French Mediterranean climate : uncertainty assessment”. *Natural Hazards and Earth System Science*. Vol. 12. no. 9, p. 2769–2784.
- VRAC, Mathieu & FRIEDERICH, Petra [2015]. “Multivariate—Intervariable, Spatial, and Temporal—Bias Correction”. *Journal of Climate*. Vol. 28. no. 1, p. 218–237.
- WHITE, R. H. & TOUMI, R. [2013]. “The limitations of bias correcting regional climate model inputs”. *Geophysical Research Letters*. Vol. 40. no. 12, p. 2907–2912.
- WILBY, R.L. & WIGLEY, T.M.L. [2000]. “Precipitation predictors for downscaling : observed and general circulation model relationships”. *International Journal of Climatology*. Vol. 20. no. 6, p. 641–661.
- WOOD, A.W., LEUNG, L.R., SRIDHAR, V. & LETTENMAIER, D.P. [2004]. “Hydrologic Implications of Dynamical and Statistical Approaches to Downscaling Climate Model Outputs”. *Climatic Change*. Vol. 62. no. 1-3, p. 189–216.
- YIOU, P., VAUTARD, R., NAVEAU, P. & CASSOU, C. [2007]. “Inconsistency between atmospheric dynamics and temperatures during the exceptional 2006/2007 fall/winter and recent warming in Europe”. *Geophysical Research Letters*. Vol. 34. no. 21.
- ZORITA, Eduardo & STORCH, Hans von [1999]. “The Analog Method as a Simple Statistical Downscaling Technique : Comparison with More Complicated Methods”. *Journal of Climate*. Vol. 12. no. 8, p. 2474–2489.



# Développement d'un modèle spatial de downscaling : SpaWGEN.

Où l'on comprend les étapes successives de ce modèle et les apports du downscaling par rapport aux modèles spatiaux classiques.

1. Introduction.....	106
2. Le cadre statistique : les processus spatiaux .....	109
3. Le modèle : SpaWGEN.....	111
3.1. Modèle marginal . . . . .	112
3.2. Processus gaussien et fonction de covariance . . . . .	113
4. Données.....	115
4.1. Observations . . . . .	115
4.2. Covariables . . . . .	116
4.3. Processus de Validation . . . . .	116
5. Évaluation du modèle .....	117
5.1. Les simulations . . . . .	118
5.2. Évaluation de la fréquence de jours de pluie . . . . .	118
5.3. Propriétés marginales . . . . .	120
5.4. Propriétés spatiales . . . . .	123
5.5. Covariance non-stationnaire . . . . .	131
6. Conclusions et perspectives.....	135
7. Synthèse des résultats .....	144



# 1. Introduction

Ce chapitre a pour but de montrer les étapes successives du développement d'un modèle de réduction d'échelle statistique dit spatial. Nous avons jusqu'à présent travaillé aux CHAPITRES II et III à l'aide de plusieurs modèles de réduction d'échelle avec une idée essentielle qui est l'intercomparaison des modèles et sous plusieurs contextes climatiques. Nous avons évalué différents aspects de ces modèles, notamment leur capacité à reproduire la cohérence spatiale des observations (*cf.* CHAPITRE II). Or, ces modèles statistiques, excepté le modèle ANALOG, ne sont pas contraints du point de vue spatial. En effet, les modèles étaient ajustés par point de grille (ou par station). Ce chapitre concerne l'*Objectif n°2* de ce travail : le développement d'un modèle générant des champs journaliers de précipitations spatialement cohérents. Depuis environ 50 ans, la question de la modélisation des précipitations a motivé de nombreux travaux notamment en raison de son importance au quotidien et dans de nombreux domaines tels que l'hydrologie, l'écologie, l'agriculture, etc. Les séries temporelles de précipitations sont essentielles aux différentes études et à la modélisation dans ces domaines. Celles-ci doivent être réalistes du point de vue temporel (événementiel) et cohérentes du point de vue spatial. En particulier, nous nous attacherons à développer un modèle de réduction d'échelle dans le cadre des générateurs de temps stochastiques.

Comme nous l'avons vu au CHAPITRE II, les modèles stochastiques posent de nombreuses pistes de travail et certains avantages qui nous intéressent tout particulièrement et qui ont motivé notre choix. En effet, la possibilité de lois marginales ayant des propriétés non-stationnaires sont extrêmement intéressantes dans un contexte de changement climatique. Le cadre des générateurs de temps stochastiques va nous permettre d'allier cet aspect à la possibilité d'introduire une cohérence spatiale dans la modélisation, ce qui est très peu disponible dans la littérature. La plupart du temps les modèles sont stationnaires [WILKS, 2010]. Historiquement, ces modèles ont été développés pour générer des séries temporelles synthétiques de variables ayant des propriétés similaires à celles des observations à l'échelle de stations [SEMENOV et al., 1998 ; WILKS & WILBY, 1999]. C'est de là que vient cette appellation de "générateurs de temps" puisque cela a permis de compléter des séries temporelles parcellaires en générant des temps (au sens météorologique).

Cependant, la modélisation des processus naturels nécessite en tant que données d'entrées, des données de précipitations ayant une bonne cohérence spatiale et temporelle. Ainsi, l'accent a été mis sur le développement d'un modèle pouvant générer des données (en général journaliers) de précipitations temporellement et/ou spatialement corrélées dans un contexte de modèle de réduction d'échelle [e.g. BARDOSSY & PLATE, 1992 ; BELLONE et al., 2000 ]. De tels modèles stochastiques peuvent être entre autres utilisés pour fournir une bonne estimation de l'incertitude liée aux simulations contrairement aux modèles déterministes basés sur des fonctions de transfert de type GAM (*cf.* CHAPITRES II et III).

Dans notre cas, les générateurs de temps sont des modèles stochastiques paramétriques, dans le sens où ce sont les paramètres du modèle qui contrôlent les précipitations à un endroit donné [WILKS, 2010]. L'utilisation des générateurs de temps pour la réduction d'échelle s'obtient en faisant varier les paramètres au moyen de covariables (ou prédicteurs). Ainsi on induit de la non-stationnarité spatiale et/ou temporelle selon la nature géographique ou temporelle des covariables. En d'autres termes, ceci

permet de tenir compte de manière consistante des changements entre le climat actuel et futur vus par les GCMs grâce aux covariables temporelles. On introduira également des covariables spatiales permettant d’une part, de générer des données où il n’y en a pas, et d’autre part de tenir compte de l’influence de la topographie sur les précipitations. Cette option de modélisation paramétrique est un choix de notre part. Notons qu’il existe des générateurs stochastiques spatiaux non-paramétriques [MARIETHOZ et al., 2010 ; JHA et al., 2015].

La particularité et la grande difficulté dans la modélisation statistique des précipitations tient à la présence d’une discontinuité en 0 dans sa fonction de répartition. Cela correspond à la partie discrète de la distribution caractérisant la présence ou l’absence de précipitations, la partie continue représentant les précipitations non nulles. Usuellement une modélisation en deux étapes est privilégiée dans laquelle les parties discrète et continue sont modélisées séparément [e.g. STERN & COE, 1984 ; WILKS, 1998 et les références qu’il contient]. C’est ce qui a été fait au CHAPITRE II pour les modèles stochastiques. L’occurrence est souvent modélisée à l’aide de chaînes de Markov d’ordre divers [pour l’ordre un voir KILSBY et al., 2007 ], comprenant aussi les chaînes de Markov non-homogènes [KATZ & PARLANGE, 1995 ; VRAC et al., 2007d] ou encore à plusieurs états [FLECHER et al., 2010]. La partie intensité est en général modélisée par une distribution paramétrique non-gaussienne : par exemple la distribution gamma [e.g. BELLONE et al., 2000 ; MEZGHANI & HINGRAY, 2009 ], la distribution de pareto généralisée [GPD, i.e. BOUVIER et al., 2003 ] ou un mélange de distribution par exemple un mélange de distributions exponentielles [WILKS, 1998] ou un mélange entre une distribution gamma et une GPD [VRAC & NAVEAU, 2007 ; CARREAU & VRAC, 2011].

Dans un contexte de processus spatiaux, plusieurs transformations ont été utilisées pour gaussianiser les données. Cela permet de considérer les précipitations à différentes stations comme une seule variable gaussienne multivariée. Ainsi on peut se placer dans un contexte de processus spatial gaussien sur lequel on reviendra. La normalisation peut être obtenue par exemple par une loi normale transformée [STEHLÍK & BÁRDOSSY, 2002 ; AILLIOT et al., 2009 ; LEBLOIS & CREUTIN, 2013] ou une transformation monotone [ce sera notre cas ; cf. BOUVIER et al., 2003 ; VISCHER et al., 2009 ; SIGRIST et al., 2012 ]. Dans ce chapitre, nous opterons pour un cadre de travail similaire permettant de générer des valeurs de précipitations à plusieurs endroits de façon cohérente.

Une grande variété de modèles a été développée pour répondre à la question suivante : comment induire une cohérence dans les précipitations simulées à plusieurs endroits distincts ? On distingue les modèles multisites et les modèles spatiaux : les premiers permettent de générer des données uniquement aux stations disponibles alors que les autres peuvent générer des précipitations indépendamment de la présence ou non d’une station. Il faut toutefois que certaines stations soient disponibles pour calibrer le modèle.

Il y a plusieurs façons de mettre en place un modèle dit multisite : une modélisation simple consiste à considérer comme spatialement et temporellement indépendant les sites conditionnellement à un régime de temps [e.g. ZUCCHINI & GUTTORP, 1991 ; HUGHES & GUTTORP, 1994 ] ou bien un modèle autologistique peut être utilisé à la place des régimes comme dans BELLONE et al. [2000]. AILLIOT et al. [2009] ont utilisé un processus spatial gaussien tronqué combiné à un modèle de Markov caché non-homogène caractérisant la transition d’un régime à un autre. Pour sa part, RASMUSSEN [2013] a développé un modèle combinant deux processus spatiaux gaussiens autorégressifs

modélisant respectivement l'occurrence et l'intensité. Une autre possibilité est d'utiliser une méthode de rééchantillonnage, comme par exemple dans BUSHAND & BRANDSMA [2001].

Du côté de la modélisation dite spatiale il existe également plusieurs stratégies pour générer des champs de précipitations sur une région entière à partir des paramètres estimés aux stations. A partir de ces paramètres on peut par exemple simuler des champs sur une grille régulière [GUILLOT, 1999; GUILLOT & LEBEL, 1999], ou combiner ce qui précède avec le krigeage des précipitations [VISCHER et al., 2009] ou encore réaliser un krigeage des paramètres pour générer directement les champs [KLEIBER et al., 2012]. Dernièrement, BURTON et al. [2008] ont développé le modèle RainSim, un générateur stochastique de champ de précipitations où les champs sont simulés grâce à un processus d'impulsion rectangulaire spatio-temporel de Neyman-Scott. LEBLOIS & CREUTIN [2013] ont quant à eux adapté un générateur de champs gaussiens – le Turning Band Method – en 3D pour générer des précipitations à haute résolution spatiale et temporelle.

L'objectif ici n'est pas d'être exhaustif. Ce sont seulement des exemples qui illustrent le propos. Il existe plusieurs articles de synthèse des travaux sur les générateurs stochastiques multisites dans un contexte stationnaire et de downscaling (sous-entendu non-stationnaire) par exemple : WILKS [2010]; WILKS [2012]; AILLIOT et al. [2015].

Dans un contexte de réduction d'échelle, le modèle GLIMCLIM développé dans CHANDLER [2002] et appliqué dans des versions modifiées dans YANG et al. [2005] et AMBROSINO et al. [2014] s'appuie sur un modèle linéaire généralisé. Il a plutôt été utilisé dans un contexte multisite. Dans un contexte multisite, il existe d'autres modèles de réduction d'échelle basés sur le conditionnement non-homogène soit par un chaîne Markov cachée [BELLONE et al., 2000] soit par des types de temps [VRAC et al., 2007d], ou encore à l'aide de réseaux de neurones [CARREAU & VRAC, 2011].

Dans la plupart des modèles évoqués jusqu'ici, l'occurrence et l'intensité des précipitations se modélisent séparément. Récemment, une approche consistant à utiliser un processus gaussien latent pour modéliser à la fois l'occurrence et l'intensité [VISCHER et al., 2009; SIGRIST et al., 2012; ALLARD & BOUROTTE, 2015; BAXEVANI & LENNARTSSON, 2015] a été introduite et ce sera l'approche utilisée dans ce chapitre. La nouveauté de ce travail réside à plusieurs niveaux :

- dans l'utilisation de ce type d'approche dans un contexte de downscaling : l'objectif étant d'étudier l'apport du downscaling et donc de la non-stationnarité temporelle dans ce contexte;
- dans l'étude de l'apport des covariables spatiales en plus des covariables temporelles pour l'estimation des paramètres de la loi marginale. Ainsi, un seul modèle marginal sera ajusté pour une région entière au lieu d'un modèle par station;
- et enfin dans l'apport d'une structure de covariance non-stationnaire du point de vue spatio-temporel (ou anisotropie); la non-stationnarité étant introduite directement dans la fonction de covariance grâce à des covariables spatiales et temporelles.

Ce chapitre s'organise de la façon suivante : dans la SECTION 2 un rappel concernant les processus spatiaux est fait. La SECTION 3 présente les différentes composantes du modèle SpaWGEN. La SECTION 4 présente les données grandes échelles et d'observations utilisées dans ce chapitre. L'évaluation sera faite à la SECTION 5. La SECTION 6 donne les conclusions et les perspectives pour ce chapitre.

## 2. Le cadre statistique : les processus spatiaux

L'étude des dépendances spatiales et spatio-temporelles est une question drainant beaucoup d'efforts en statistique. En effet, on constate une explosion des besoins en données pour répondre aux questions fondamentales de notre société telles que le climat, la santé, l'économie, la finance et même les élections [PAVIA et al., 2008] etc. qui mettent en jeu des processus spatio-temporels. Ainsi, considérer les observations indépendantes n'est plus valide dans ce contexte. Désormais on les considère comme dépendantes spatialement et temporellement ce qui complique considérablement l'inférence statistique et la prédiction.

La modélisation spatiale est actuellement au coeur de nombreuses disciplines scientifiques. La plupart des outils de la modélisation spatiale sont issus de la géostatistique. Celle-ci est apparue suite à une volonté d'obtenir une estimation précise des réserves d'une mine d'or à partir de quelques mesures. Les équations existent depuis la fin des années 30 [KOLMOGOROV, 1939] sans pouvoir les résoudre faute de moyens informatiques suffisamment puissants à l'époque. Les premières applications ont été réalisées dans le domaine de l'exploration minière en Afrique du Sud par KRIGE [1952] et SICHEL [1952] suivies par des applications en hydrologie et sylviculture (ou gestion des forêts). C'est dans ce contexte que les techniques de krigeage ont été développées. Mais ceci demeure insuffisant pour résoudre de façon générique un large éventail de problèmes et requiert un cadre théorique plus étoffé.

C'est ainsi que Georges Matheron, en s'inspirant entre autres des travaux de Danie Krige et Herbert Sichel, put unifier tous leurs travaux dans le cadre unique des géostatistiques [MATHERON, 1971] et mettre en place un outil permettant l'analyse de la dépendance spatiale des variables d'intérêts : le variogramme. Avec l'avancée de la puissance de calcul, l'extension à de nouveaux domaines s'est alors rapidement produite. Des domaines tels que l'étude des sols, l'hydrogéologie, l'agriculture, les sciences de l'environnement, l'écologie et plus récemment la santé, la sociologie, le développement de réseaux divers etc. ont pu en bénéficier. CRESSIE & WIKLE [2011] donnent un état des lieux des dernières avancées de l'analyse des données spatio-temporelles.

Il existe plusieurs classes de modèles spatiaux qui permettent d'estimer les paramètres et de simuler un processus aléatoire spatial. Dans notre cas, nous allons nous placer uniquement dans le cadre des processus gaussiens. C'est une des familles de processus stochastiques les plus utilisées. Voici quelques définitions et quelques rappels sur les propriétés des processus gaussiens qui nous seront nécessaires dans la suite.

Soit un domaine  $\mathcal{D} \in \mathbb{R}^d$  (typiquement  $d = 2$ ) et  $s_1, \dots, s_n$ , un ensemble de points de ce domaine. La distribution du processus aléatoire  $\{Y(s) : s \in \mathcal{D}\}$  est définie par toutes les lois de probabilités jointes de dimension finie suivantes :

$$F(y_1, \dots, y_n; s_1, \dots, s_n) = \mathbb{P}(Y(s_1) \leq y_1, \dots, Y(s_n) \leq y_n), \quad (\text{IV.1})$$

pour tout  $n$  et quel que soit l'ensemble  $(s_1, \dots, s_n)$  de sites dans  $\mathcal{D}$ . Le théorème d'existence de Kolmogorov [BILLINGSLEY, 2008] énonce que le processus stochastique est valide si l'ÉQUATION IV.1 reste valable quelles que soient les permutations des sites et la marginalisation.

**Définition IV.1** *Un processus aléatoire  $\{Y(s) : s \in \mathcal{D}\}$  est dit gaussien si toutes les lois de dimension finie de l'ÉQUATION IV.1 sont des distributions gaussiennes multivariées. C'est à dire que la densité de probabilité du vecteur  $\mathbf{Y} = (Y(s_1), \dots, Y(s_n))^T$  est de la forme :*

$$f(\mathbf{y}) = \frac{1}{\sqrt{(2\pi)^n \det(\mathbf{C})}} \exp \left( -\frac{1}{2} (\mathbf{y} - \boldsymbol{\mu})^T \mathbf{C}^{-1} (\mathbf{y} - \boldsymbol{\mu}) \right) \quad (\text{IV.2})$$

où  $\mathbf{y} = (y_1, \dots, y_n)^T$ ,  $\boldsymbol{\mu} = (E(Y(s_1)), \dots, E(Y(s_n)))^T$  est le vecteur des espérances et  $\mathbf{C}$  est la matrice de covariance dont les différents éléments sont  $C_{i,j} = \text{Cov}(Y(s_i), Y(s_j))$ . Il existe une fonction :

$$C: \begin{cases} \mathcal{D} \times \mathcal{D} \longrightarrow \mathbb{R} \\ s_i, s_j \longmapsto \text{Cov}(Y(s_i), Y(s_j)) \end{cases} \quad (\text{IV.3})$$

appelée fonction de covariance.

Un processus spatial est stationnaire si les lois jointes de dimension finie sont invariantes par translation. Dans le cas d'un processus gaussien, ceci implique :

$$E[Y(s_i)] = \mu; \quad \text{Cov}(Y(s_i), Y(s_j)) = C(s_j - s_i) \quad (\text{IV.4})$$

pour tout  $s_i, s_j \in \mathcal{D}$ . Dans le cas des processus non gaussiens, la condition de l'ÉQUATION IV.4 correspond à la *stationnarité du second ordre*. En d'autres termes cela correspond à la stationnarité du moment d'ordre deux : la fonction de covariance. Un outil permettant d'étudier et d'estimer ce moment est le variogramme [MATHERON, 1971]. Le variogramme d'un processus spatial se définit de la façon suivante :

$$\gamma(h) = \frac{1}{2} \text{Var}(Y(s+h) - Y(s)) \quad (\text{IV.5})$$

Dans le cas d'une stationnarité du second ordre, le variogramme devient  $\gamma(h) = C(0) - C(h)$ . Un processus aléatoire  $Y(\cdot)$  est dit intrinsèquement stationnaire d'ordre 0 si :

$$E[Y(s+h) - Y(s)] = 0 \text{ and } \text{Var}[Y(s+h) - Y(s)] = 2\gamma(h) \quad (\text{IV.6})$$

pour tout couple  $s, s+h \in \mathcal{D}$ , le variogramme prend alors la forme  $\gamma(h) = \frac{1}{2} E[(Y(s+h) - Y(s))^2]$ .

Usuellement il est préférable d'utiliser le variogramme  $\gamma(h)$  au lieu de la fonction de covariance parce que le variogramme existe pour l'hypothèse la moins contraignante de stationnarité intrinsèque et l'estimation faite à partir du variogramme se révèle en général plus robuste que celle réalisée à partir de la fonction de covariance [cf. CRESSIE & WIKLE, 2011; CHILÈS & DELFINER, 1999 pour plus de détails sur l'estimation du variogramme et de la fonction de covariance]. Nous allons considérer

dans un premier temps un processus gaussien stationnaire avec une fonction de covariance stationnaire (cf. ÉQUATION IV.4). La fonction de covariance dépend alors uniquement de la distance  $|s_j - s_i|$ , elle est qualifiée d'*isotrope*. Une nomenclature générale nomme ce type de fonction définie de  $\mathcal{D} \times \mathcal{D}$  dans  $\mathbb{R}$  comme *noyau* (ou kernel en anglais). Ceci est issu de la théorie des opérateurs intégraux (ou à noyau), dans laquelle on définit la fonctionnelle  $T_k$  suivante :

$$(T_k f)(\mathbf{s}) = \int_{\mathcal{D}} k(\mathbf{s}, \mathbf{s}') f(\mathbf{s}') d\mu(\mathbf{s}') \quad (\text{IV.7})$$

où  $\mu$  est une mesure (en général celle de Lebesgue, cf. RASMUSSEN & WILLIAMS [2006] annexe A.7 pour plus de détails). Un noyau réel  $k$  est dit symétrique si  $k(\mathbf{s}, \mathbf{s}') = k(\mathbf{s}', \mathbf{s})$  : une fonction de covariance est donc symétrique d'après cette définition. Ainsi en reprenant les notations précédentes, la fonction  $C(\cdot, \cdot)$  et la matrice de covariance  $\mathbf{C}$  associée sont symétriques. Une matrice réelle  $\mathbf{C}$ ,  $n \times n$  est semi-définie positive (SDP) si  $\mathbf{v}^T \mathbf{C} \mathbf{v} \geq 0$  pour tous les vecteurs  $\mathbf{v} \in \mathbb{R}^n$ . Si  $\mathbf{v}^T \mathbf{C} \mathbf{v} = 0$ , lorsque  $\mathbf{v} = 0$ ,  $\mathbf{C}$  est définie positive. Même si une matrice correspondant à un noyau n'est pas nécessairement SDP, celle correspondant à une fonction de covariance l'est. Notons que toutes les définitions et propriétés définies jusqu'ici peuvent être étendues aux processus spatio-temporels en remplaçant  $Y(\mathbf{s})$  par  $Y(\mathbf{s}, \mathbf{t})$ .

Plus de détails et d'éléments théoriques à propos des processus spatiaux sont disponibles dans ADLER [1981] et STEIN [1999], notamment en ce qui concerne les propriétés de continuité et de dérivabilité d'un processus spatial. On abordera cela succinctement dans l'ANNEXE B.

### 3. Le modèle : SpaWGEN

Dans cette partie, nous allons présenter les différentes composantes du modèle spatial de downscaling statistique des précipitations développé dans ce chapitre. Différentes options seront envisagées pour chacune d'elles. La base de ce modèle repose sur l'utilisation d'un champ gaussien latent pour modéliser l'occurrence et une transformation de ce même champ latent pour modéliser les cumuls de précipitations positifs. Nous privilégions cela à une modélisation de l'occurrence et de l'intensité en deux étapes pour deux raisons : réduire le nombre de paramètres estimés et maintenir la cohérence spatiale entre occurrence et intensité.

Ainsi le champ de précipitations  $Y(\mathbf{s}, t)$  à la position  $\mathbf{s}$  et à l'instant  $t$  dépend du champ gaussien latent  $Z(\mathbf{s}, t)$ , selon la relation suivante :

$$Y(\mathbf{s}, t) = \begin{cases} \Psi(Z(\mathbf{s}, t)), & \text{si } Z(\mathbf{s}, t) > T \\ 0, & \text{si } Z(\mathbf{s}, t) \leq T \end{cases} \quad (\text{IV.8})$$

où  $\Psi$  est une fonction monotone non décroissante qu'on appellera anamorphose dans la suite et  $T$  un seuil dépendant de  $\Psi$  comme on le verra dans la suite. Le champ  $Y(\mathbf{s}, t)$  se définit comme méta-gaussien. Ce lexique a été introduit dans KELLY & KRZYSZTOFOWICZ [1997] et utilisé par exemple dans BARDOSSY & PLATE [1992]; GUILLOT [1999]; GUILLOT & LEBEL [1999]; STEHLÍK & BÁRDOSSY [2002]. Se placer dans ce cadre méta-gaussien présente deux avantages principaux :

ce cadre est en théorie compatible avec n'importe quelle distribution marginale [cf. BELL, 1987; SHAH et al., 1996; LEBEL et al., 1998; GUILLOT, 1999; BOUVIER et al., 2003 pour des exemples d'utilisation] ensuite le champ gaussien latent est complètement défini par ses deux premiers moments (moyenne et fonction de covariance) comme décrit à la SECTION 2 de ce chapitre tout en gardant une bonne flexibilité.

### 3.1. Modèle marginal

La formulation de l'ÉQUATION IV.8 amène une modélisation des cumuls de précipitations positifs par un champs gaussien tronqué et transformé. Nous avons vu dans l'introduction qu'il existait plusieurs possibilités pour modéliser les cumuls de précipitations. Nous nous limiterons volontairement à une distribution gamma ( $\gamma_{\alpha,\beta}(\cdot)$ ) pour des raisons de simplification de l'estimation des paramètres. Nous reviendrons sur cette question dans les discussions de ce chapitre où nous testerons une GPD et on évoquera également d'autres possibilités. Nous nous concentrons dans cette étude sur la comparaison de deux anamorphoses différentes.

$$\begin{aligned}\Psi_1 &= F_{s,t}^{-1} \circ \Phi \\ \Psi_2 &= F_{\gamma s,t}^{-1} \circ \Phi_\mu\end{aligned}\tag{IV.9}$$

où  $F_{s,t}$ ,  $\Phi$ ,  $F_{\gamma s,t}$  et  $\Phi_\mu$  sont respectivement les fonctions de répartition (ou cdf) du mélange entre la distribution gamma de paramètres alpha et beta ( $\gamma_{\alpha,\beta}(\cdot)$ ) et l'atome en zéro (avec une probabilité de  $P_0$  que le jour soit sec), de la distribution gaussienne centrée réduite ( $\mathcal{N}_{0,1}(\cdot)$ ), de la distribution  $\gamma_{\alpha,\beta}(\cdot)$  et de la gaussienne tronquée en zéro avec une moyenne  $\mu$  et une variance unitaire. Nous donnons les formulations explicites de  $F_{s,t}$  et de  $\Phi_\mu$ .

$$F(x) = \begin{cases} P_0 & \text{si } x = 0 \\ P_0 + (1 - P_0) \cdot F_\gamma(x) & \text{si } x > 0 \end{cases}\tag{IV.10}$$

$$\Phi_\mu(x) = \begin{cases} 0 & \text{si } x \leq 0 \\ \frac{\Phi(x - \mu) - \Phi(-\mu)}{\Phi(\mu)} & \text{si } x > 0 \end{cases}\tag{IV.11}$$

Les anamorphoses  $\Psi_1$  et  $\Psi_2$  ont été respectivement inspirées de VISCHER et al. [2009] et de BAXEVANI & LENNARTSSON [2015]. La formulation de  $\Psi$  dans l'ÉQUATION IV.8 est complètement définie à partir des paramètres que ce soit pour  $\Psi_1$  ou  $\Psi_2$ . Ainsi nous pouvons réécrire l'ÉQUATION IV.8 dans les deux cas :

$$Y(\mathbf{s}, t) = \begin{cases} F_{s,t}^{-1} \circ \Phi(Z(\mathbf{s}, t)), & \text{si } Z(\mathbf{s}, t) > \Phi^{-1}(P_0(\mathbf{s}, t)) \\ 0, & \text{si } Z(\mathbf{s}, t) \leq \Phi^{-1}(P_0(\mathbf{s}, t)) \end{cases}\tag{IV.9 - \Psi_1}$$

$$Y(\mathbf{s}, t) = \begin{cases} F_{\gamma s,t}^{-1} \circ \Phi_\mu(Z(\mathbf{s}, t)), & \text{si } Z(\mathbf{s}, t) > 0 \\ 0, & \text{si } Z(\mathbf{s}, t) \leq 0 \end{cases}\tag{IV.9 - \Psi_2}$$

Il reste à estimer les paramètres des anamorphoses : à savoir le paramètre de forme ( $\alpha$ ) et d'intensité ( $\beta$ ) de la loi gamma dans les deux cas,  $P_0$  pour  $\Psi_1$  et  $\mu$  pour  $\Psi_2$ . Dans ce chapitre, nous restons dans le cadre des modèles linéaires généralisés (GLM) introduit aux CHAPITRES II et III pour les modèles SWG et SWG-s. La raison principale à cela est que ce choix nous offre la possibilité d'introduire de la non stationnarité dans la distribution marginale. On exprime donc  $\alpha$  et  $\beta$  en fonction des prédicteurs pour la station  $\mathbf{s}$  un jour  $t$  de la façon suivante :

$$\begin{cases} \log(\alpha(\mathbf{s}, t)) &= \alpha^0 + \sum_{j=1}^N \alpha^j X_j(\mathbf{s}, t), \\ \log(\beta(\mathbf{s}, t)) &= \beta^0 + \sum_{j=1}^N \beta^j X_j(\mathbf{s}, t), \end{cases} \quad (\text{IV.13})$$

où  $\{X_j\}$  est l'ensemble des prédicteurs (cf. SECTION 4.2). De même qu'au CHAPITRE II, nous utilisons la régression logistique pour estimer le paramètre  $P_0$  de l'anamorphose  $\Psi_1$ . On a donc pour un jour donné  $t$  et à la station  $\mathbf{s}$ , la probabilité d'occurrence  $p(\mathbf{s}, t)$  (qui est en fait  $1 - P_0(\mathbf{s}, t)$ ) :

$$\begin{cases} \log\left(\frac{p(\mathbf{s}, t)}{1 - p(\mathbf{s}, t)}\right) &= \overbrace{P^0 + \sum_{j=1}^N P^j X_j(\mathbf{s}, t)}^{=S}, \\ \Leftrightarrow p(\mathbf{s}, t) &= \frac{\exp(S)}{1 + \exp(S)}. \end{cases} \quad (\text{IV.14})$$

Il reste à estimer le paramètre  $\mu$  pour  $\Psi_2$  dont la formulation nous permet d'écrire la relation suivante :

$$p(\mathbf{s}, t) = \mathbb{P}(Y(\mathbf{s}, t) > 0) = \mathbb{P}(Z(\mathbf{s}, t) > 0) = \Phi(\mu(\mathbf{s}, t)) \quad (\text{IV.15})$$

d'où

$$\mu(\mathbf{s}, t) = \Phi^{-1}(p(\mathbf{s}, t)). \quad (\text{IV.16})$$

Cela revient à estimer  $p(\mathbf{s}, t)$ , on utilise donc le résultat de l'ÉQUATION IV.14. Ainsi nous avons estimé tous les paramètres nécessaires aux deux anamorphoses. L'estimation a été faite à l'aide du package R "VGAM" [YEE, 2010].

### 3.2. Processus gaussien et fonction de covariance

Nous venons de voir à la section précédente deux anamorphoses nous permettant de simuler un processus spatial modélisant les précipitations à partir d'un processus gaussien. Cependant, étant données les contraintes imposées par la distribution marginale, en particulier la discontinuité en 0, il n'existe pas de correspondance évidente entre la covariance des observations et celle du processus gaussien sous-jacent. GUILLOT [1999] et LEBLOIS & CREUTIN [2013] utilisent une expansion polynomiale afin d'approximer la covariance du processus gaussien à partir de la covariance des observations. VISCHER et al. [2009] ont utilisé une simplification de cela en normalisant la fonction de covariance estimée à partir des observations par la variance de celles-ci. Ceci a donné de bons résultats dans un contexte de simulations conditionnelles stationnaires. Dans le cas d'une transformation où les jours



secs sont censurés comme dans le cas de l'anamorphose  $\Psi_2$ , ALLARD & BOUROTTE [2015] ont mis en place une estimation par maximum de la vraisemblance (MV) composite (par paires) alors que BAXEVANI & LENNARTSSON [2015] ont eux utilisé une estimation par méthode des moments en deux étapes : dans un premier temps, ils donnent une estimation de la covariance par paire de stations et ensuite ils estiment la fonction de covariance par la méthode des moments. Dans ce chapitre, le but étant de comparer deux anamorphoses, les structures de covariance dans les deux cas sont uniquement estimées à partir des données transformées par MV. Ceci sera néanmoins discuté et remis en question dans la SECTION 5 de ce chapitre. Nous allons décrire les différentes structures de covariances que nous désirons tester.

Comme nous l'avons vu à la SECTION 2, un processus gaussien se définit par ses deux premiers moments. Dans la section précédente, nous avons défini deux anamorphoses qui par construction imposent le vecteur moyenne du champ gaussien sous-jacent. Dans le cas de l'anamorphose  $\Psi_1$  (cf. ÉQUATION IV.9 –  $\Psi_1$ ) la moyenne est  $\boldsymbol{\mu} = 0$  pour l'ensemble des sites, pour l'anamorphose  $\Psi_2$  (cf. ÉQUATION IV.9 –  $\Psi_2$ ) la moyenne est  $\boldsymbol{\mu}_t = (\Phi^{-1}(p(s_1, t)), \dots, \Phi^{-1}(p(s_n, t)))^T$ . On doit désormais définir la structure de covariance. Pour ce faire, nous allons utiliser des fonctions de covariance valides dans le cas de processus gaussiens stationnaires respectant les propriétés énoncées à la SECTION 2. Dans le cas stationnaire, la fonction de covariance est uniquement fonction de  $\boldsymbol{\tau} = |\mathbf{s} - \mathbf{s}'|$ , c'est à dire  $C(\boldsymbol{\tau}|\boldsymbol{\lambda})$  (où  $\boldsymbol{\lambda}$  est l'ensemble des paramètres de la fonction de covariance). Nous allons tester deux fonctions de covariance :

la fonction de Matérn [STEIN, 1999] :

$$C(\boldsymbol{\tau}) = \sigma^2 \frac{1}{\Gamma(\nu)2^{\nu-1}} \left(2\sqrt{\nu}\frac{\boldsymbol{\tau}}{\rho}\right)^\nu K_\nu \left(2\sqrt{\nu}\frac{\boldsymbol{\tau}}{\rho}\right), \quad (\text{IV.17})$$

où  $\Gamma$  est la fonction gamma (à ne pas confondre avec la distribution gamma),  $K_\nu$  est la fonction modifiée de Bessel de seconde espèce, avec les paramètres de portée  $\rho$  et de rugosité  $\nu$  [ou encore appelé ordre de différentiabilité PACIOREK & SCHERVISH, 2006] qui sont des paramètres non-négatifs et puisque les distributions marginales ont une variance unitaire, l'écart-type  $\sigma$  est égal à un. Nous allons également tester la covariance exponentielle qui est un cas particulier de la fonction de Matérn pour  $\nu = \frac{1}{2}$  :

$$C(\boldsymbol{\tau}) = \sigma^2 \exp\left(\frac{-\boldsymbol{\tau}}{\rho}\right) \quad (\text{IV.18})$$

Dans les deux cas, les paramètres seront estimés par maximum de vraisemblance. La fonction de log-vraisemblance a la forme suivante :

$$LL(\mathbf{Z}|\boldsymbol{\lambda}) = \sum_{\{\mathbf{Z}\}} \log(f(\mathbf{Z})) \quad (\text{IV.19})$$

avec

- $\mathbf{Z} = (z_1, \dots, z_{n_{station}})$  sont les champs gaussiens journaliers,
- $f(\mathbf{Z})$  est la distribution gaussienne multivariée (ÉQUATION IV.2).

Ces deux fonctions de covariance sont, comme on l'a dit précédemment, stationnaires et isotropes.

## 4. Données

### 4.1. Observations

Dans ce chapitre, nous utilisons des données de précipitations journalières : les séries quotidiennes de référence (SQR) développées par Météo France. Nous avons un réseau de 69 stations disposées sur le pourtour méditerranéen. Ces stations ont été sélectionnées uniquement si elles ne présentent pas de données manquantes. Leur distribution spatiale ainsi que leur altitude est présentée sur la FIGURE IV.1. L'altitude des stations varie de 1m (Aigues-Mortes) en bord de mer à 1690m (Arvieux) dans les Alpes. Seule la période allant du 1<sup>er</sup> janvier 1979 au 31 décembre 2014 est considérée ici et cela à cause de la disponibilité des données grandes échelles (*cf.* SECTION 4.2). La densité du réseau est assez variable : les deux stations les plus proches se situent à un peu plus de 4km. La station la plus isolée possède uniquement deux stations dans un rayon de 100 km dont la plus proche se situe à près de 88 km alors que d'autres peuvent avoir jusqu'à 36 stations dans ce même rayon. La région d'étude est largement influencée par deux massifs montagneux au nord (le Massif Central et les Alpes) et un à l'ouest (les Pyrénées) et par la mer Méditerranée au sud. Dans les observations, la plus petite valeur positive de cumul de précipitations journalières est de 0.1mm.

Mediterranean SQR Stations

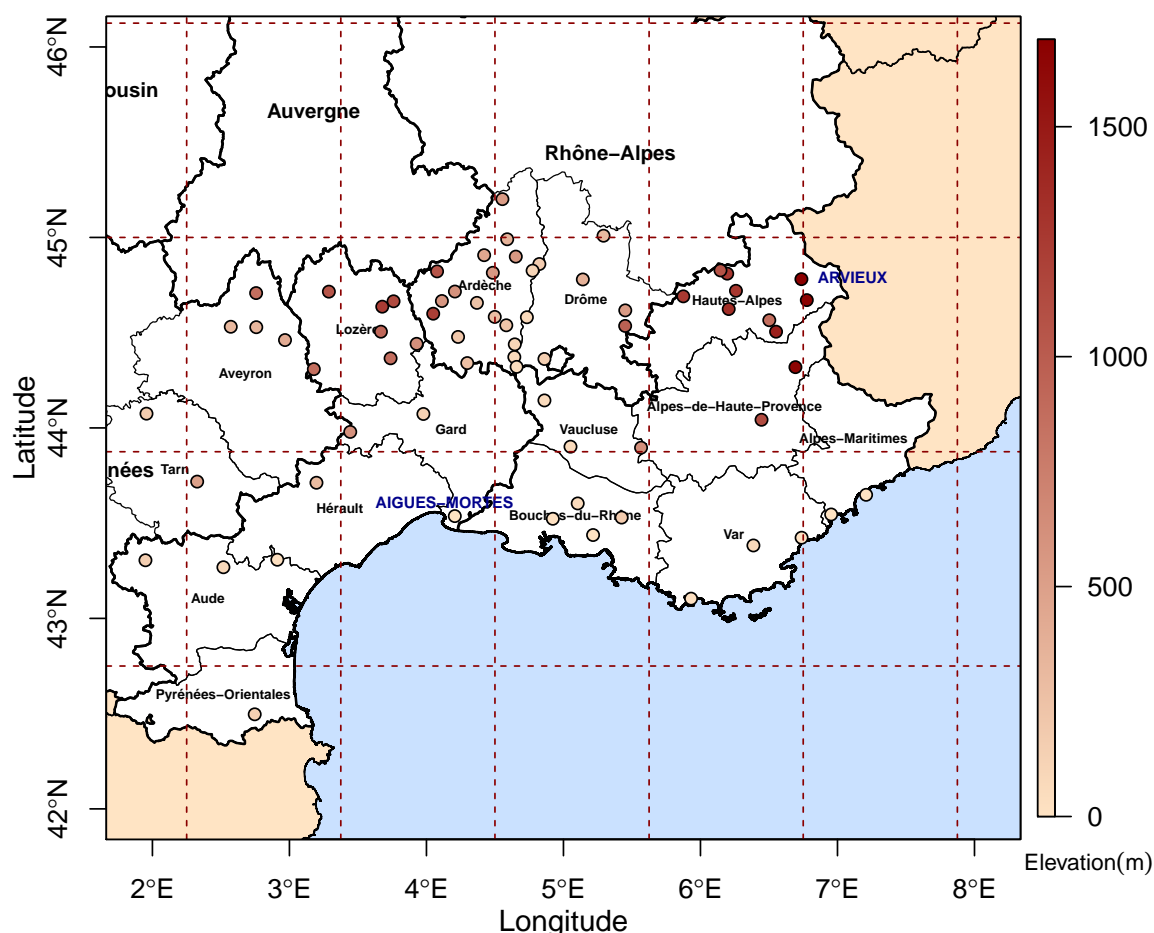


FIGURE IV.1 – Les positions et l'élévation des stations des SQR et les mailles ERA-I couvrant le domaine des stations (en tireté) sont représentées ici.

## 4.2. Covariables

Ce chapitre s'inscrit dans un contexte de développement d'un nouveau modèle spatial de downscaling statistique suivant le cadre théorique défini à la SECTION 3. Un certain nombre de covariables géographiques et temporelles sont utilisées ici. Nous choisissons les coordonnées spatiales longitude (X), latitude (Y) et l'altitude (Z) en tant que covariables géographiques et les données issues des Réanalyses ERA-interim [ERA-I, DEE et al., 2011] en tant que prédicteurs temporels. Nous reprenons les mêmes variables qu'aux CHAPITRES II et III : la température de rosée à 2m (D2), la température à 2m (T2), la pression au niveau de la mer (MSL), les composantes zonale et méridionale du vent et la hauteur du géopotential au niveau de pression de 850 hPa (U850, V850 and Z850). Dans ce chapitre, nous n'utiliserons pas les PCs comme précédemment : le travail de pré-traitement des prédicteurs temporels est simplifié au maximum et nous utilisons la série temporelle à grande-échelle dont le point de grille contient la station et les valeurs des prédicteurs sont centrées et réduites. La FIGURE IV.1 indique en tireté les mailles ERA-I en question.

## 4.3. Processus de Validation

Nous faisons l'hypothèse d'un modèle non-stationnaire spatialement et temporellement. Pour tester la robustesse de ce modèle nous utilisons une procédure de calibration-validation spatio-temporelle. Temporellement, la calibration se fera sur la période du 1<sup>er</sup> janvier 1979 au 31 Décembre 2004 et la projection (et l'évaluation) sur la période du 1<sup>er</sup> janvier 2005 au 31 Décembre 2014. Spatialement, la calibration se fait sur deux tiers des stations en choisissant deux stations sur trois en fonction de la latitude. La FIGURE IV.2 présente en rouge les 46 stations utilisées pour la calibration et en bleu les 23 qui servent à la validation.

La calibration se fera de façon mensuelle et les résultats seront présentés d'un point de vue annuel ou saisonnier (sur les quatre saisons usuelles hémisphère nord, i.e. DJF, MAM, JJA, SON). Nous testerons dans la suite plusieurs options de modélisation en particulier trois combinaisons de prédicteurs dans la modélisation de la loi marginale : SpaWGEN désignera un modèle utilisant toutes les covariables spatiales et temporelles (à savoir X, Y, Z, D2, MSL, T2, U850, V850 et Z850), SpaWGEN-surf désignera un modèle utilisant toutes les covariables spatiales et les covariables temporelles de surface uniquement (à savoir X, Y, Z, D2, MSL et T2) et enfin SpaWGEN-s désignera un modèle utilisant uniquement les covariables spatiales (à savoir X, Y, Z) et donc temporellement stationnaire.

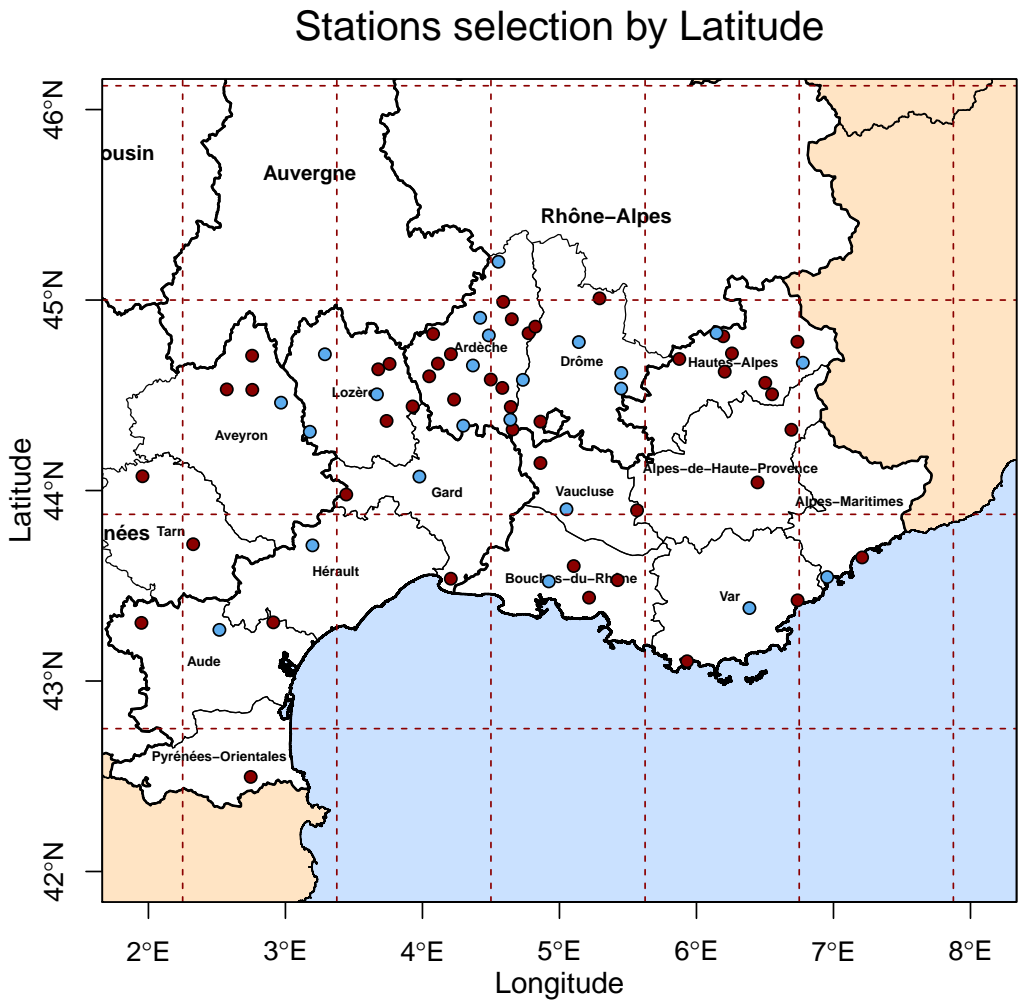


FIGURE IV.2 – Les stations rouges sont utilisées pour la calibration et les bleues pour la validation.

## 5. Évaluation du modèle

Dans cette section, la performance de plusieurs variantes du modèle présenté à la SECTION 3 est évaluée (*cf.* TABLEAU IV.1). Pour ce faire nous allons générer 100 simulations sur la période 1979-2014 pour chacune des variantes du modèle.

SpaWGEN : les options						
	$\Psi_1$		$\Psi_2$			
	Matérn	Exp.	Matérn	Exp.	Matérn NS	Exp. NS
SpaWGEN	✓	✓	✓	✓	✓	✓
SpaWGEN-surf	✓	✓	✓	✓	✗	✗
SpaWGEN-s	✓	✓	✓	✓	✗	✗

Tableau IV.1 – Ce tableau résume les différentes combinaisons de simulation possibles de ce chapitre. On a combiné les anamorphoses  $\Psi_1$  et  $\Psi_2$ , avec les trois combinaisons de prédicteurs définies à la SECTION 4.3 (SpaWGEN, SpaWGEN-surf, SpaWGEN-s) pour estimer la loi marginale et les deux fonctions de covariance Matérn et exponentielle (Exp.). NS indique que la fonction de covariance a été employée dans sa formulation non-stationnaire comme définie à la SECTION 5.5.  
✓ indique que la simulation a été faite et ✗ que non.

Le TABLEAU IV.1 précédent résume toutes les options de modélisation et les différentes combinaisons qui seront testées dans la suite. On commence par évaluer les douze variantes les plus à gauche du tableau ayant un champ gaussien latent stationnaire. Dans un premier temps, les observations sont transformées selon chacune des anamorphoses.

$$z(\mathbf{s}, t) = \begin{cases} \Phi^{-1}[F(y)] & \text{if } y > 0 \\ \Phi^{-1}[U[0, P_0]] & \text{if } y = 0 \end{cases} \quad (\text{IV.20a})$$

$$z(\mathbf{s}, t) = \begin{cases} \Phi_{\mu}^{-1}[P_0 + (1 - P_0) \cdot F_{\gamma}(y)] & \text{if } y > 0 \\ \Phi_{\mu}^{-1}[P_0] & \text{if } y = 0 \end{cases} \quad (\text{IV.20b})$$

L'ÉQUATION IV.20A correspond à l'anamorphose  $\Psi_1$  de l'ÉQUATION IV.9 [transformation  $m_2$  de VISCHER et al., 2009]. Pour cette anamorphose les valeurs positives sont transformées selon  $\Psi_1^{-1}$  et les valeurs nulles sont remplacées par des valeurs tirées aléatoirement dans  $[0, P_0]$  transformées par la CDF inverse de la loi normal centrée réduite ( $\Phi^{-1}$ ). Pour l'anamorphose  $\Psi_2$  l'ÉQUATION IV.20B est une adaptation de la transformation utilisée dans BAXEVANI & LENNARTSSON [2015]. En l'occurrence, les valeurs positives sont transformées selon  $\Psi_2^{-1}$  et les valeurs nulles sont remplacées par des valeurs  $P_0$  transformée par  $\Phi_{\mu}^{-1}$ . Ainsi les observations sont normalisées et cela nous permet de travailler dans le cadre du processus gaussien, lequel est défini par ses deux premiers moments. Nous avons déjà la moyenne dans les deux cas (*cf.* SECTION 3.2, pour rappel  $\mu = 0$  pour  $\Psi_1$  et  $\mu_t = (\Phi^{-1}(p(s_1, t)), \dots, \Phi^{-1}(p(s_n, t)))^T$  pour  $\Psi_2$ ). Il reste à estimer les paramètres des différentes fonctions de covariance (*cf.* ÉQUATIONS IV.17 et IV.18).

## 5.1. Les simulations

Les simulations des précipitations sont réalisées selon les deux étapes suivantes :

1. Un champ gaussien aléatoire journalier  $Z(\mathbf{s}, t)$  est généré à partir des fonctions de covariance estimées,
2. Les valeurs de  $Z(\mathbf{s}, t)$  inférieures ou égales aux seuils (*cf.* ÉQUATIONS IV.9 –  $\Psi_1$  et IV.9 –  $\Psi_2$ ) correspondent aux jours secs. Les autres valeurs de  $Z(\mathbf{s}, t)$  sont transformées en cumuls de précipitations grâce aux anamorphoses estimées à la SECTION 3.1 tel que  $Y(\mathbf{s}, t) = \Psi(Z(\mathbf{s}, t))$ .

On rappelle que nous testons trois calibrations en terme de prédicteurs : SpaWGEN, SpaWGEN-surf et SpaWGEN-s (*cf.* SECTION 4.3 pour le détail des variables utilisées).

## 5.2. Évaluation de la fréquence de jours de pluie

Il s'agit d'évaluer la qualité de l'estimation de la fréquence de jours de pluie  $P_0$ . L'estimation se fait à l'aide d'une régression logistique décrite à la SECTION 3.1. La FIGURE IV.3 donne le pourcentage hivernal moyen (DJF) de jours de pluie estimé pour chaque station en fonction du pourcentage observé pour les trois calibrations. À gauche, nous avons les pourcentages sur la période de calibration, à droite sur la période de projection.

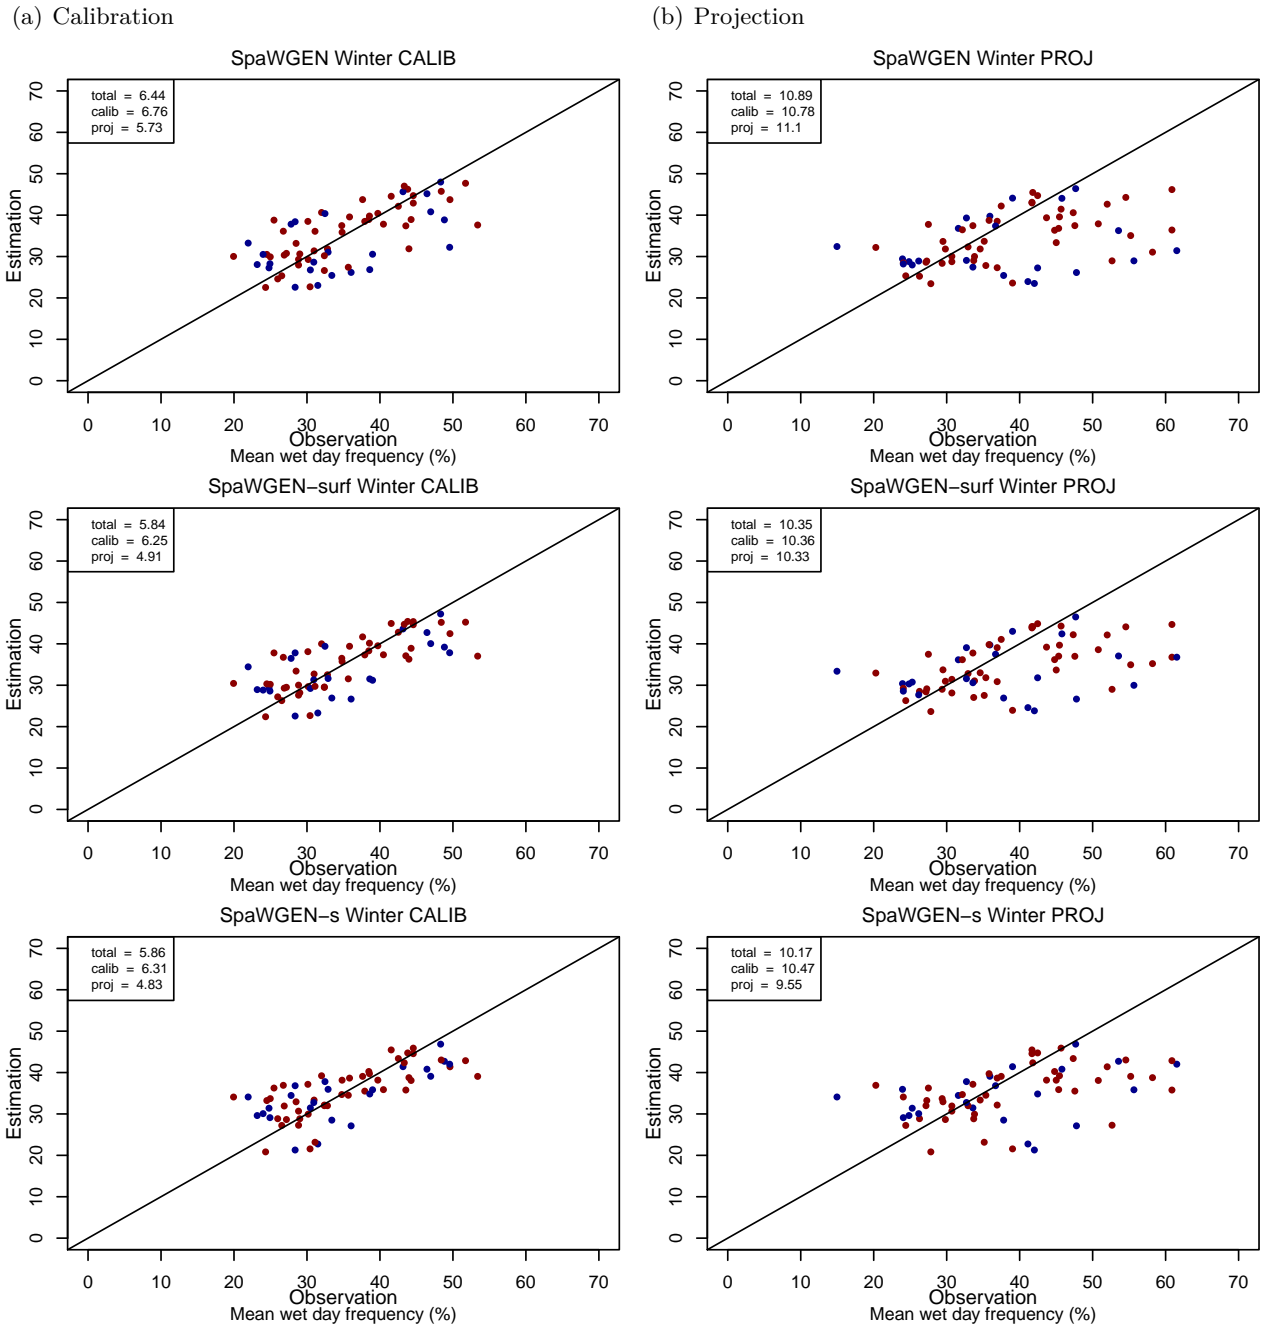


FIGURE IV.3 – Pourcentage hivernal moyen de jours de pluie estimée pour chaque station en fonction du pourcentage observé, avec en rouge les stations de calibration et en bleu les stations de validation. Nous avons à gauche les pourcentages sur la période de calibration (a), à droite sur la période de projection (b). Dans l’encadré, on a la moyenne des différences entre estimations et observations pour toutes les stations (“total”), pour les stations utilisées pour la calibration (“calib”) et pour la validation (“proj”) (cf. FIGURE IV.2).


En rouge, ce sont les stations utilisées pour la calibration et en bleu celles qui servent à la validation. Pour les trois modèles, on a jusqu’à 15% de différence entre observation et estimation sur la période de calibration et jusqu’à 25% sur la période de projection quelle que soit la station. Quel que soit l’ensemble de prédicteurs utilisé pour la calibration, on observe très peu de différences d’une calibration à l’autre. Les biais de l’estimation sont assez importants, ce qui potentiellement pourrait biaiser les simulations (ce résultat est valable pour les autres saisons).

### 5.3. Propriétés marginales

La FIGURE IV.4 donne le biais relatif moyen hivernal journalier pour une simulation sur les périodes de calibration/projection pour les trois calibrations combinées aux deux anamorphoses et deux fonctions de covariance différentes. Les biais relatifs sont dans l'ensemble assez importants entre -200% et 60% environ. Globalement les biais sont plus importants pour la période de projection. La calibration SpaWGEN-s a tendance à surestimer la moyenne quelle que soit l'anamorphose ou la fonction de covariance et c'est SpaWGEN-surf qui présente les biais les plus faibles. Les simulations avec la structure de covariance exponentielle surestiment plutôt la moyenne pour les deux anamorphoses et les trois calibrations. Pour la covariance de Matérn on n'observe pas vraiment de tendance. Il est néanmoins assez difficile de discriminer les simulations en se basant uniquement sur ce critère.

(a) Calibration – exponentielle

(b) Projection – exponentielle



(c) Calibration – Matérn

(d) Projection – Matérn




FIGURE IV.4 – Biais relatif moyen hivernal journalier en pourcentage pour une simulation par modèle par rapport aux observations. Nous avons *à gauche* les biais sur la période de calibration, *à droite* sur la période de projection, *en haut* pour une fonction de covariance exponentielle, *en bas* pour une fonction de covariance de Matérn. Sur chacun des panneaux, on retrouve six modèles : les trois calibrations combinées aux deux anamorphoses différentes  $\Psi_1$  et  $\Psi_2$ .

#### Variabilité interannuelle

Pour avoir une idée plus précise des propriétés marginales, la variabilité interannuelle est étudiée. Dans les figures suivantes, nous avons représenté la moyenne des séries de cumuls hivernaux de précipitations obtenues sur les stations servant à la validation.

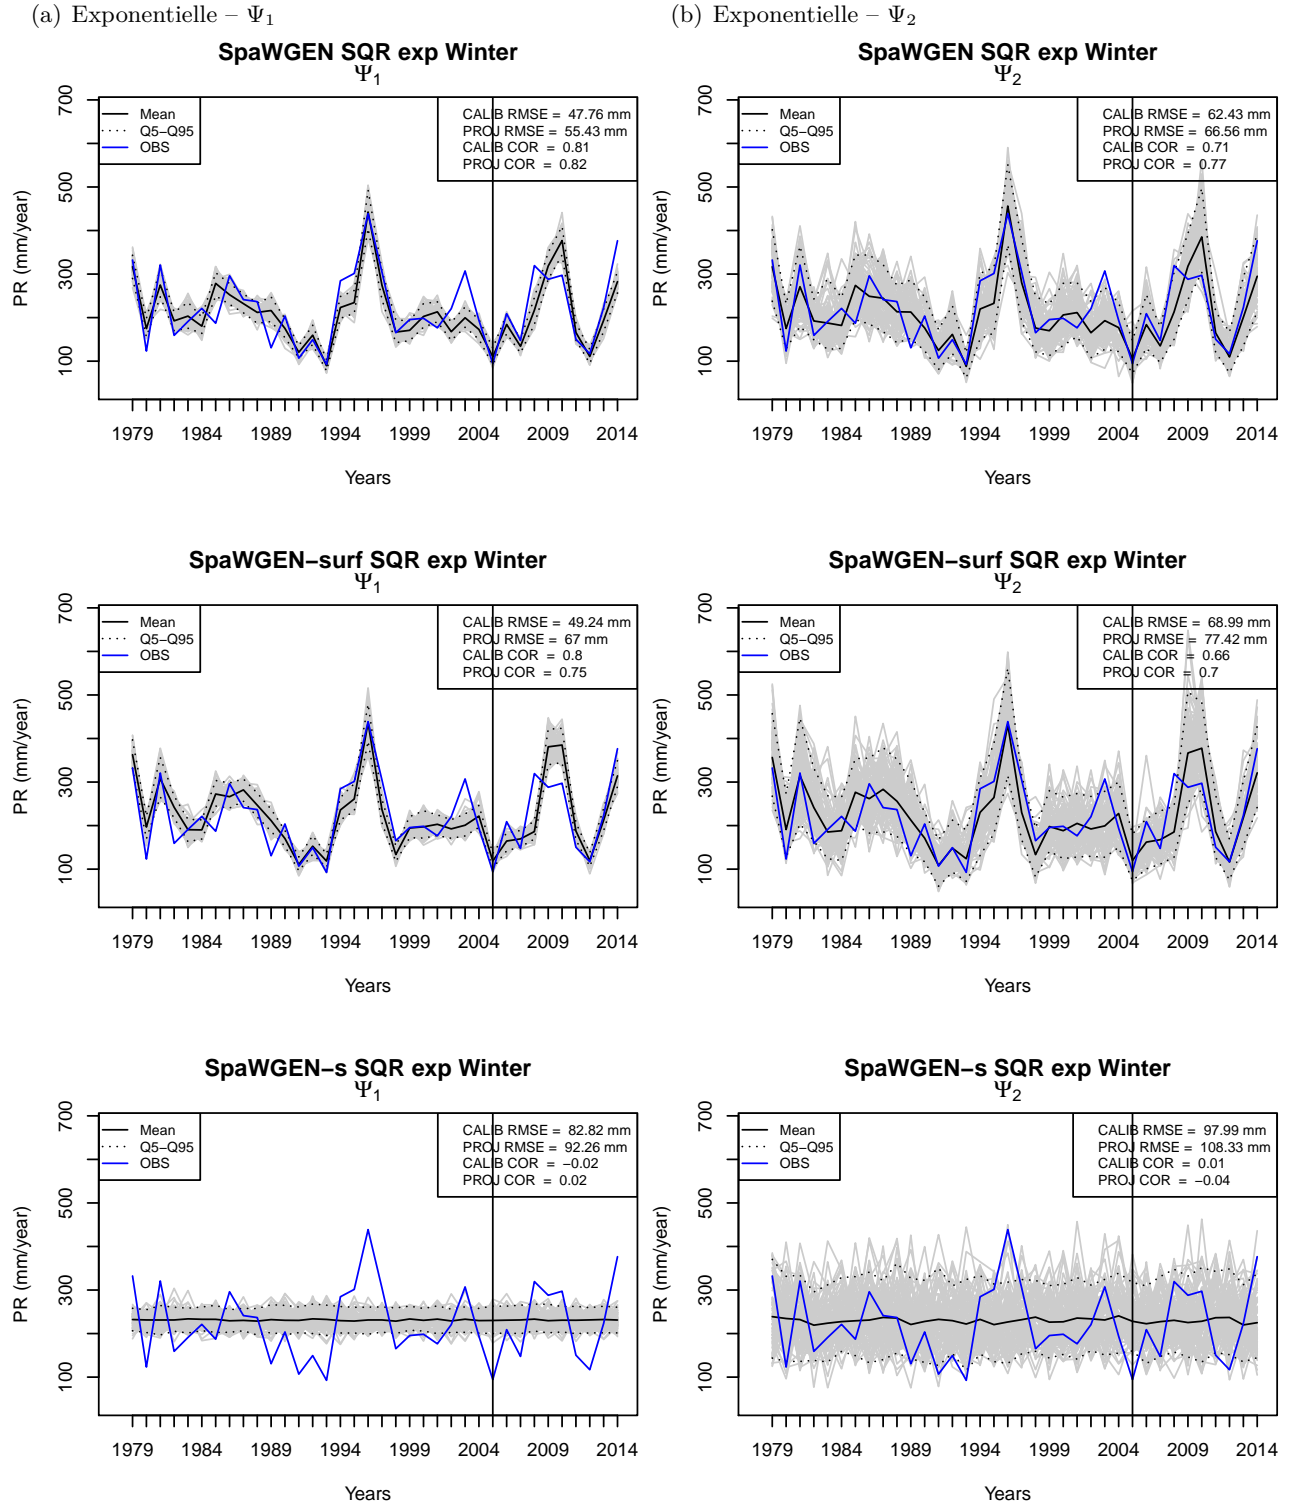


FIGURE IV.5 – Séries temporelles des cumuls hivernaux de précipitations pour les trois calibrations avec une covariance exponentielle pour l'anamorphose  $\Psi_1$  (gauche) et  $\Psi_2$  (à droite). Ces séries sont la moyenne des séries obtenues sur les stations servant à la validation, en *bleu* les observations, en *trait plein noir* la moyenne des simulations, en *gris* l'ensemble des 100 simulations et en *pointillé* l'intervalle  $Q_5 - Q_{95}$  et la barre verticale délimite les périodes de calibration et de validation. Dans l'encadré est présenté la moyenne des corrélations et de l'erreur moyenne quadratique (RMSE) entre les simulations et les observations sur les deux périodes.



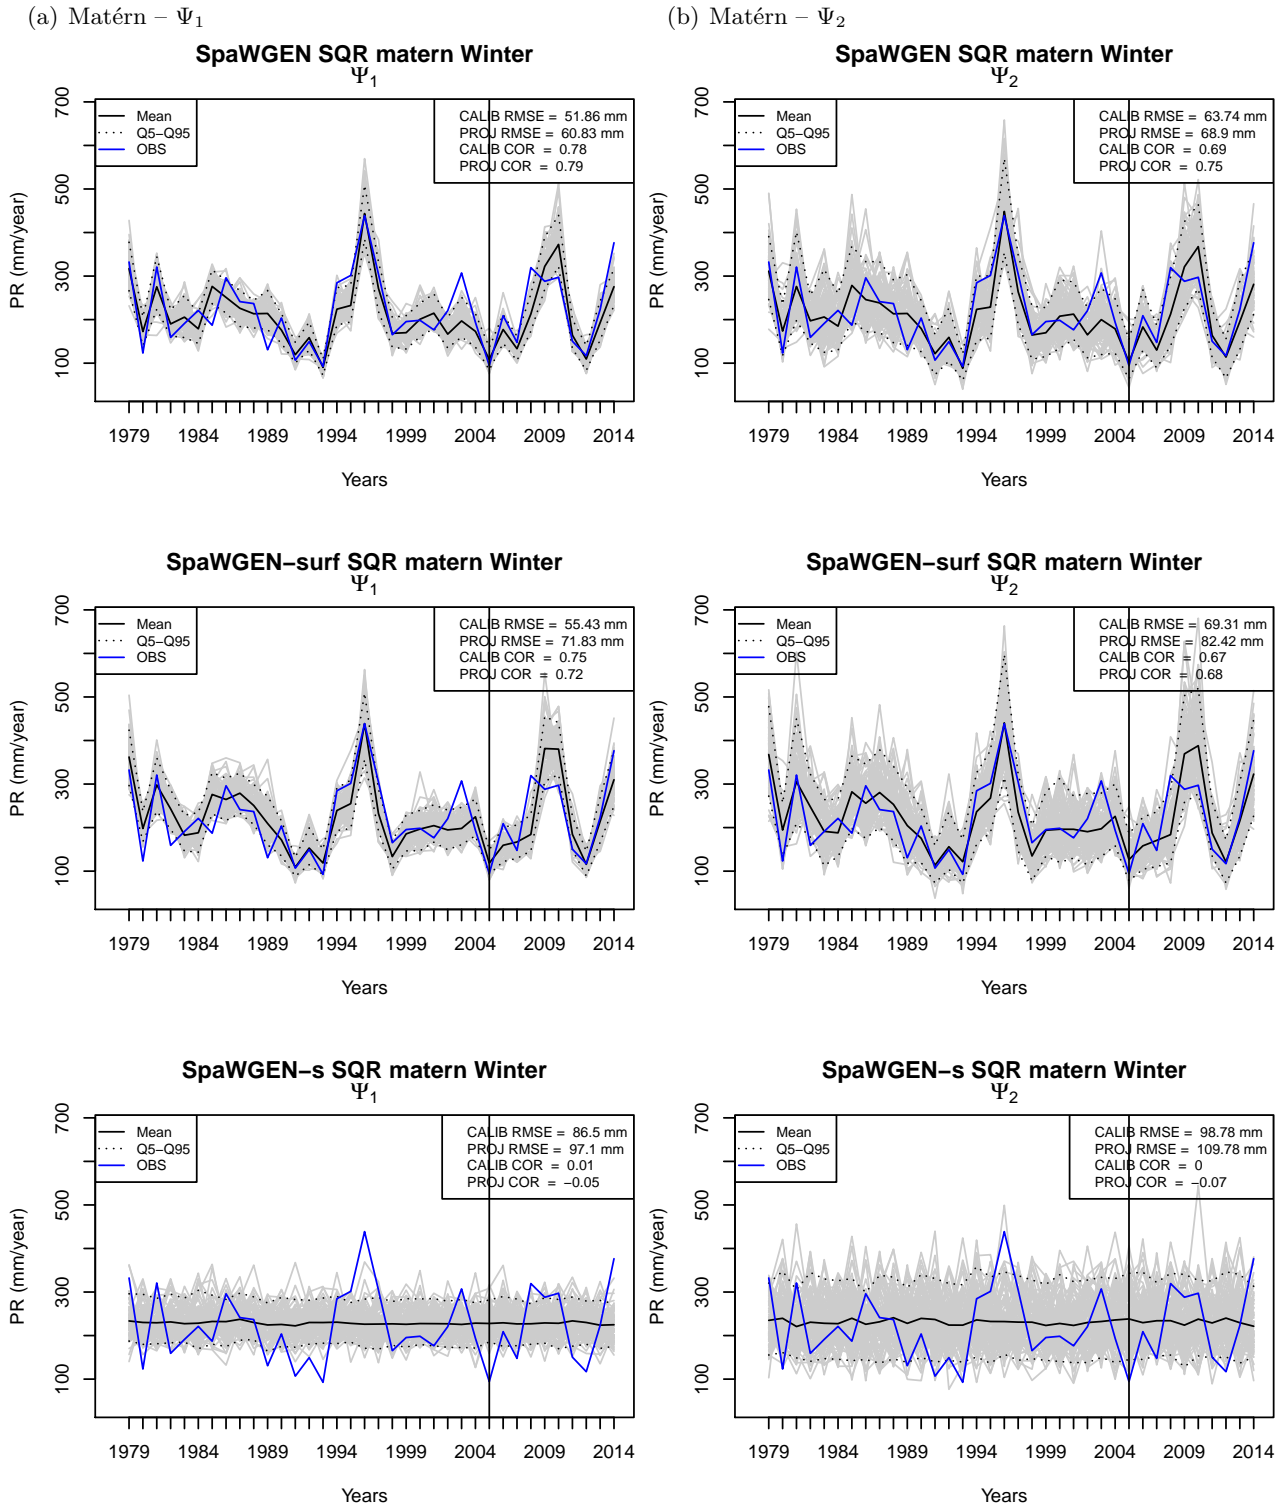


FIGURE IV.6 – Idem que précédemment pour la fonction de covariance de Matérn.

Grâce aux FIGURES IV.5 et IV.6 nous faisons deux constats (valables pour les autres saisons) :

- 1- Quelle que soit la fonction de covariance la variabilité interannuelle du signal moyen est sensiblement équivalente entre les anamorphoses  $\Psi_1$  et  $\Psi_2$ . Néanmoins, pour une année donnée, la variabilité interne aux 100 simulations est bien plus importante pour  $\Psi_2$  que pour  $\Psi_1$ . Cette différence est essentiellement due à la façon dont l'occurrence est gérée. En effet, dans le cas de  $\Psi_1$ , nous avons transformé les observations en données gaussiennes où les zéros sont remplacés

par des valeurs tirées aléatoirement dans l'intervalle  $[0, P_0]$  sur lesquelles on ajuste un champ gaussien avec une moyenne nulle et une fonction de covariance. Une partie de la variance du champ est captée par ces valeurs et est “perdue” lorsque que l’on revient dans l’espace des observations après avoir simulé le champ gaussien.

- 2- On voit clairement l’apport des prédicteurs temporels dans ce contexte. L’enveloppe des simulations suit la variabilité des observations lorsqu’on introduit des covariables temporelles, alors que lorsqu’il n’y a que des covariables géographiques (SpaWGEN-s), on voit clairement la stationnarité temporelle des simulations.

### *Cycle Saisonnier*

Nous rappelons que les modèles ont été calibrés de façon mensuelle afin de préserver un cycle saisonnier correct. Nous analysons le cycle en question. Il est représenté à la FIGURE IV.7 pour les deux anamorphoses pour la fonction de covariance exponentielle. On a également représenté ici la moyenne sur les stations servant à la validation. On constate que la différence entre les différentes calibrations est quasi-négligeable, ce qui est probablement dû à la calibration mensuelle. On observe de nouveau la différence de variabilité générée par les deux anamorphoses :  $\Psi_1$  génère moins de variabilité que  $\Psi_2$ . On voit également l’apport des covariables temporelles : le cycle saisonnier change entre la période de calibration et de projection. En effet le maximum du cycle annuel est observé en octobre sur la période de calibration alors qu’il apparaît en novembre sur la période de validation. On voit que pour les deux anamorphoses les calibrations SpaWGEN et SpaWGEN-surf permettent ce changement de cycle même si ce n’est pas parfait. Quant à SpaWGEN-s on constate aucun changement du cycle d’une période à l’autre. On constate néanmoins une augmentation de la variabilité sur la période de projection par rapport à la période de calibration. Ceci est également valable pour les deux autres calibrations SpaWGEN et SpaWGEN-surf.

L’étude de la variabilité interannuelle et du cycle saisonnier a mis en évidence l’importance et l’intérêt d’inclure des covariables temporelles. Avec de tels prédicteurs, les modèles peuvent potentiellement être utilisés dans un contexte de changement climatique. De plus, cela permet de faire l’économie d’une modélisation saisonnière [BAXEVANI & LENNARTSSON, 2015] des paramètres faite à partir de la calibration mensuelle. Dans le cas de la fonction de Matérn, on fait dans l’ensemble le même constat quant à l’intérêt d’introduire de la non-stationnarité dans la modélisation de la loi marginale par l’inclusion de covariables temporelles du point de vue de la variabilité interannuelle et le cycle saisonnier (*cf.* ANNEXE C).

## **5.4. Propriétés spatiales**

Nous allons maintenant étudier la capacité des modèles à reproduire la structure spatiale des observations. Dans un premier temps, intéressons-nous au corrélogramme. Les FIGURES IV.8 et IV.9 représentent les corrélogrammes hivernaux sur la période de projection respectivement pour l’anamorphose  $\Psi_1$  et  $\Psi_2$  pour les deux fonctions de covariance.

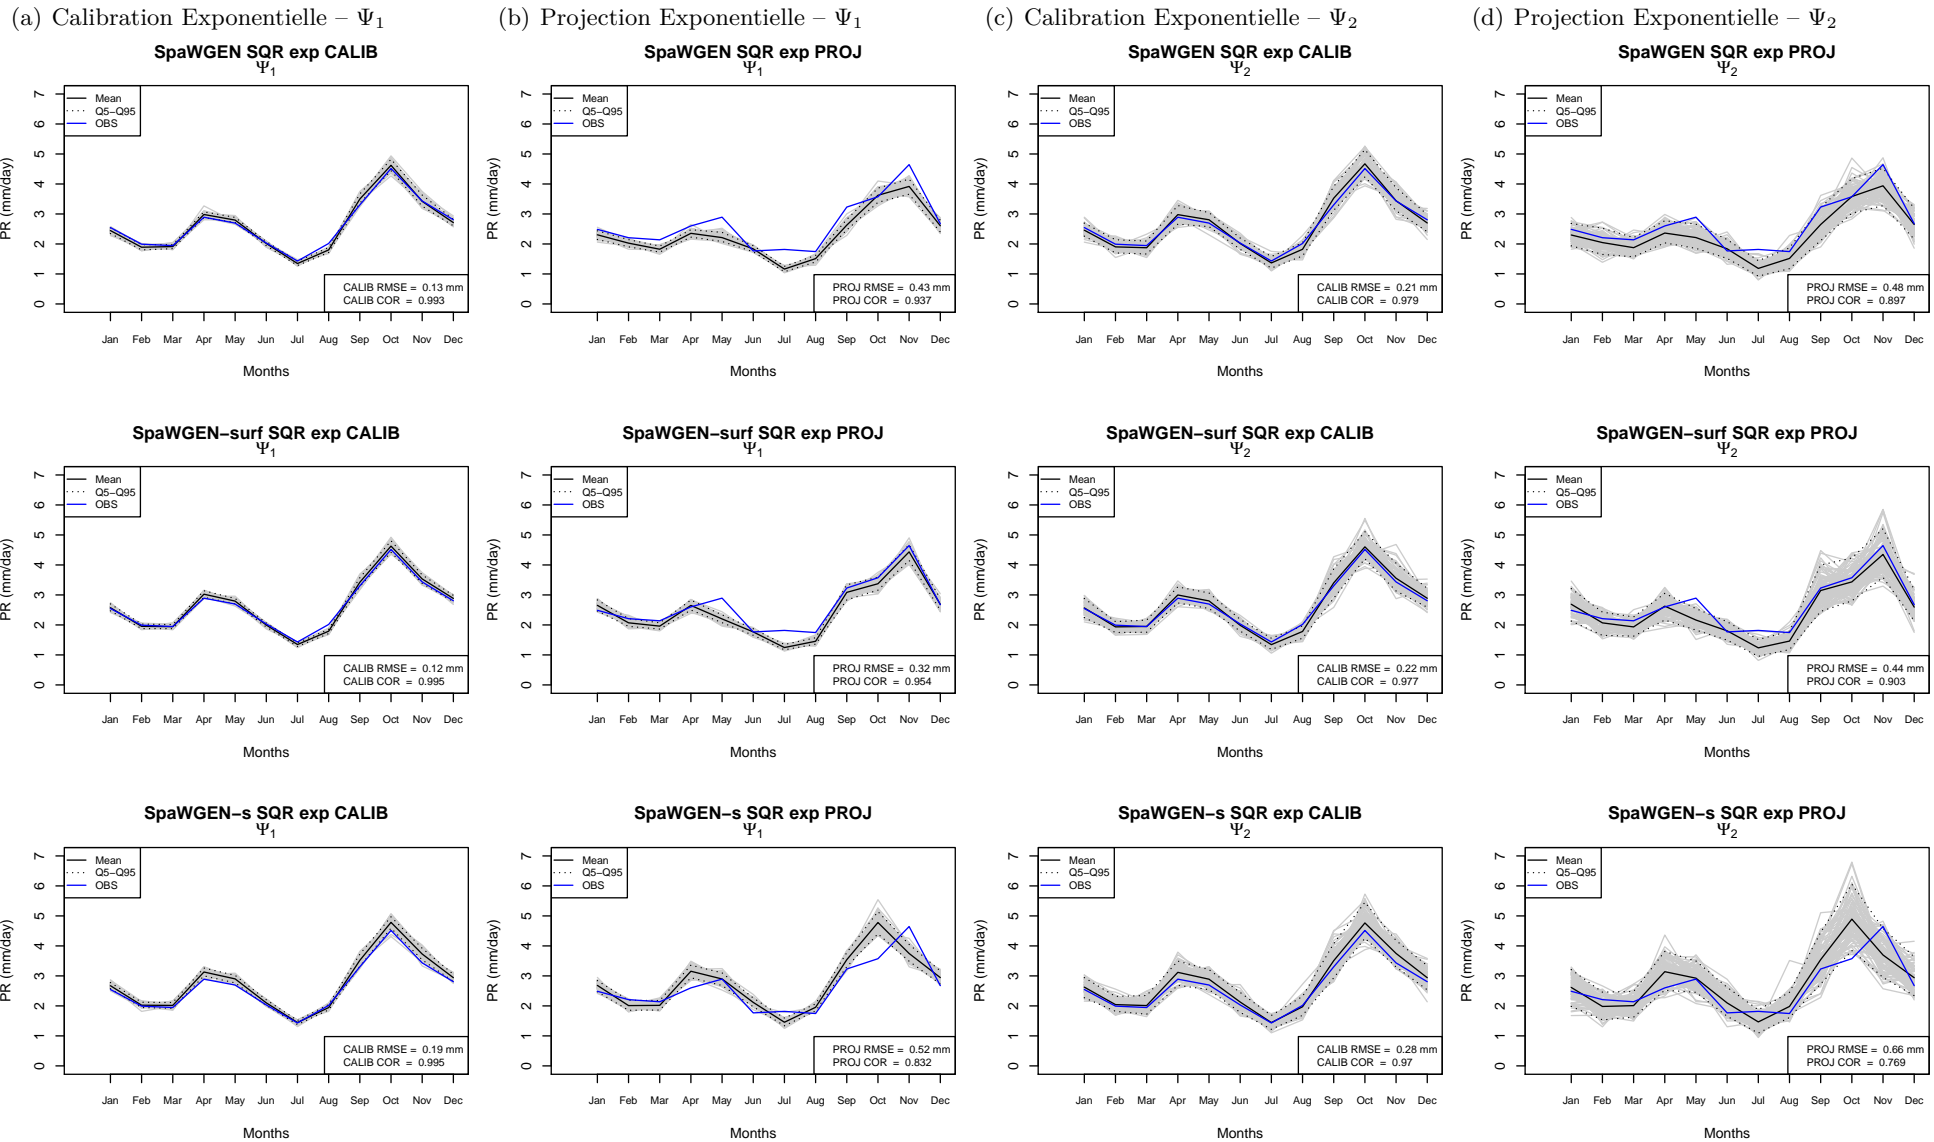


FIGURE IV.7 – Séries temporelles des moyennes mensuelles des cumuls de précipitations pour les trois calibrations avec une covariance exponentielle pour l'anamorphose  $\Psi_1$  (à gauche) sur la période de calibration (a) et de projection (b) et  $\Psi_2$  (à droite) sur la période de calibration (c) et de projection (d). Ces séries sont la moyenne des séries obtenues sur les stations servant à la validation, en bleu, les observations, en trait plein noir la moyenne des simulations, en gris l'ensemble des 100 simulations et en pointillé l'intervalle  $Q_5 - Q_{95}$ . Dans l'encadré sont présentées les moyennes des corrélations et de la racine carrée de l'erreur moyenne quadratique (RMSE) entre les simulations et les observations.

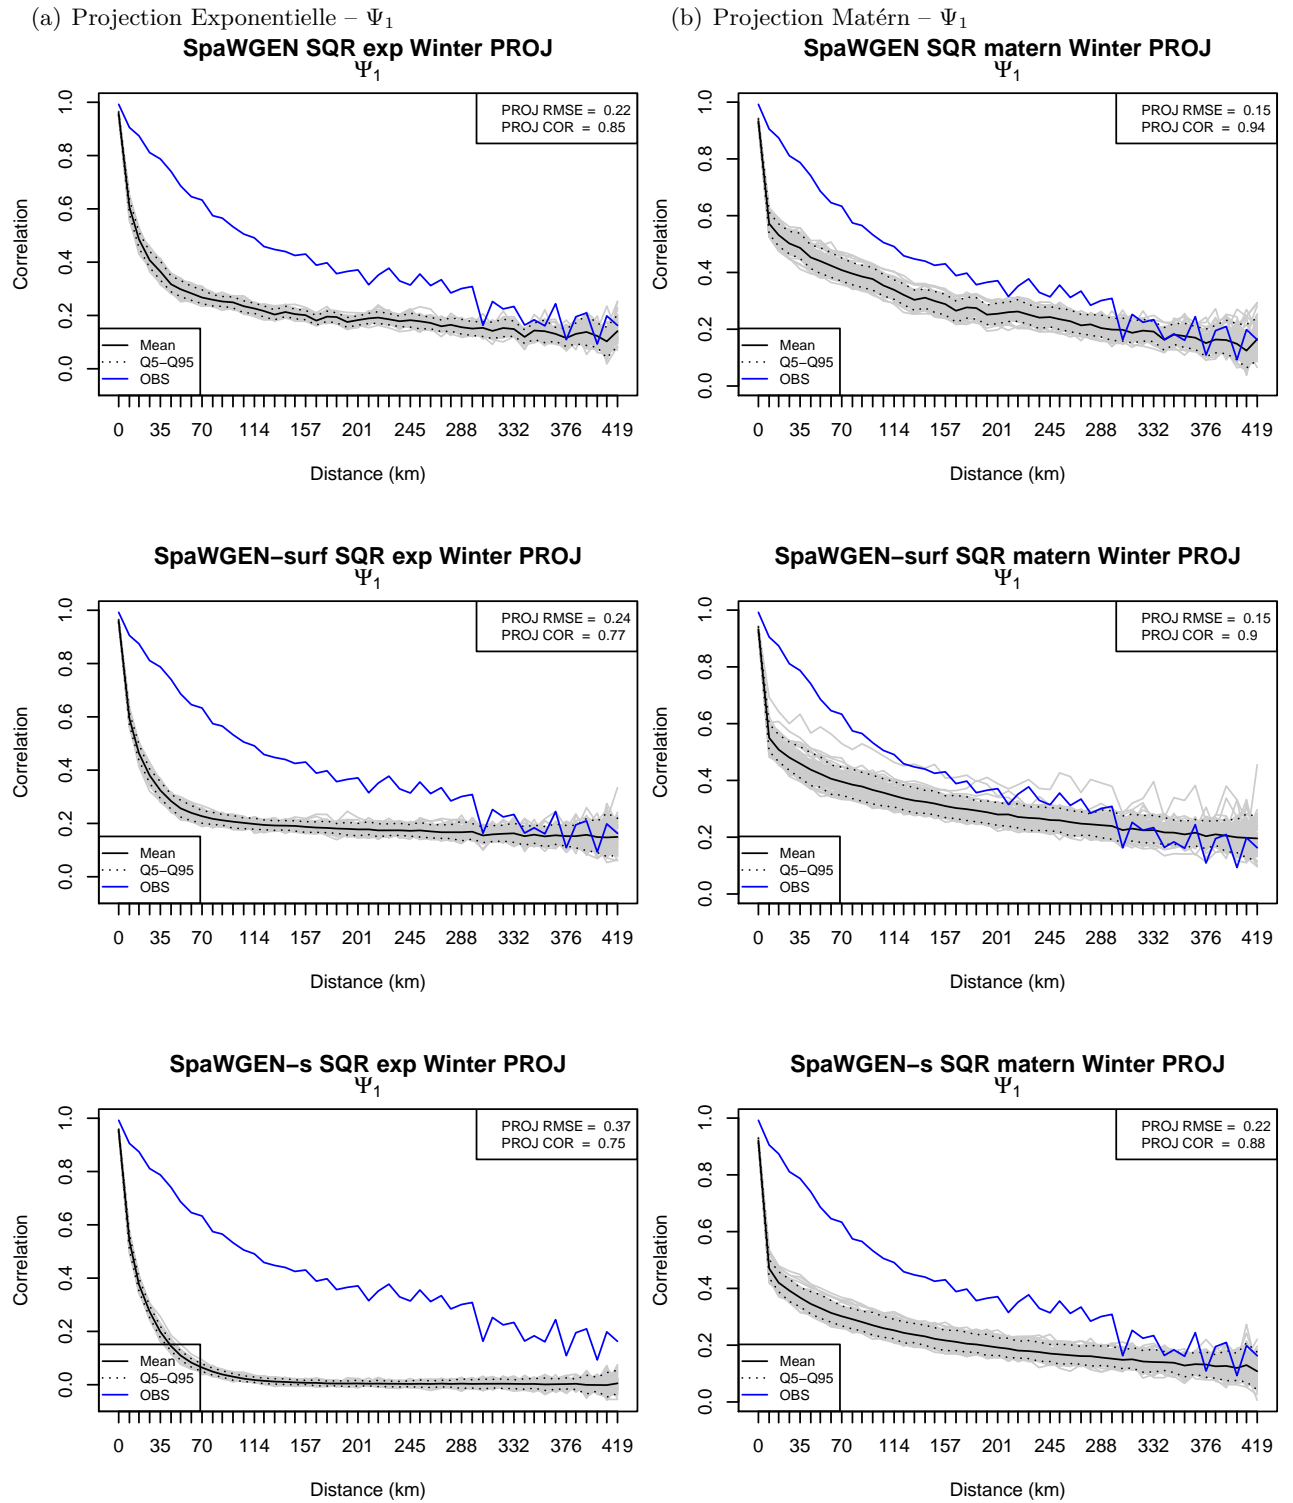


FIGURE IV.8 – Corrélrogramme hivernaux pour l'anamorphose  $\Psi_1$  sur la période de projection pour la fonction de covariance exponentielle (à gauche) et de Matérn (à droite). Le corrélrogramme des observations est représenté en bleu, en trait plein noir le corrélrogramme moyen des simulations, en gris ceux de l'ensemble des 100 simulations et en pointillé l'intervalle  $Q_5 - Q_{95}$ . Dans l'encadré, sont représentés les moyennes des corrélations et de la racine carrée de l'erreur quadratique moyenne (RMSE) entre le corrélrogramme des simulations et celui des observations.

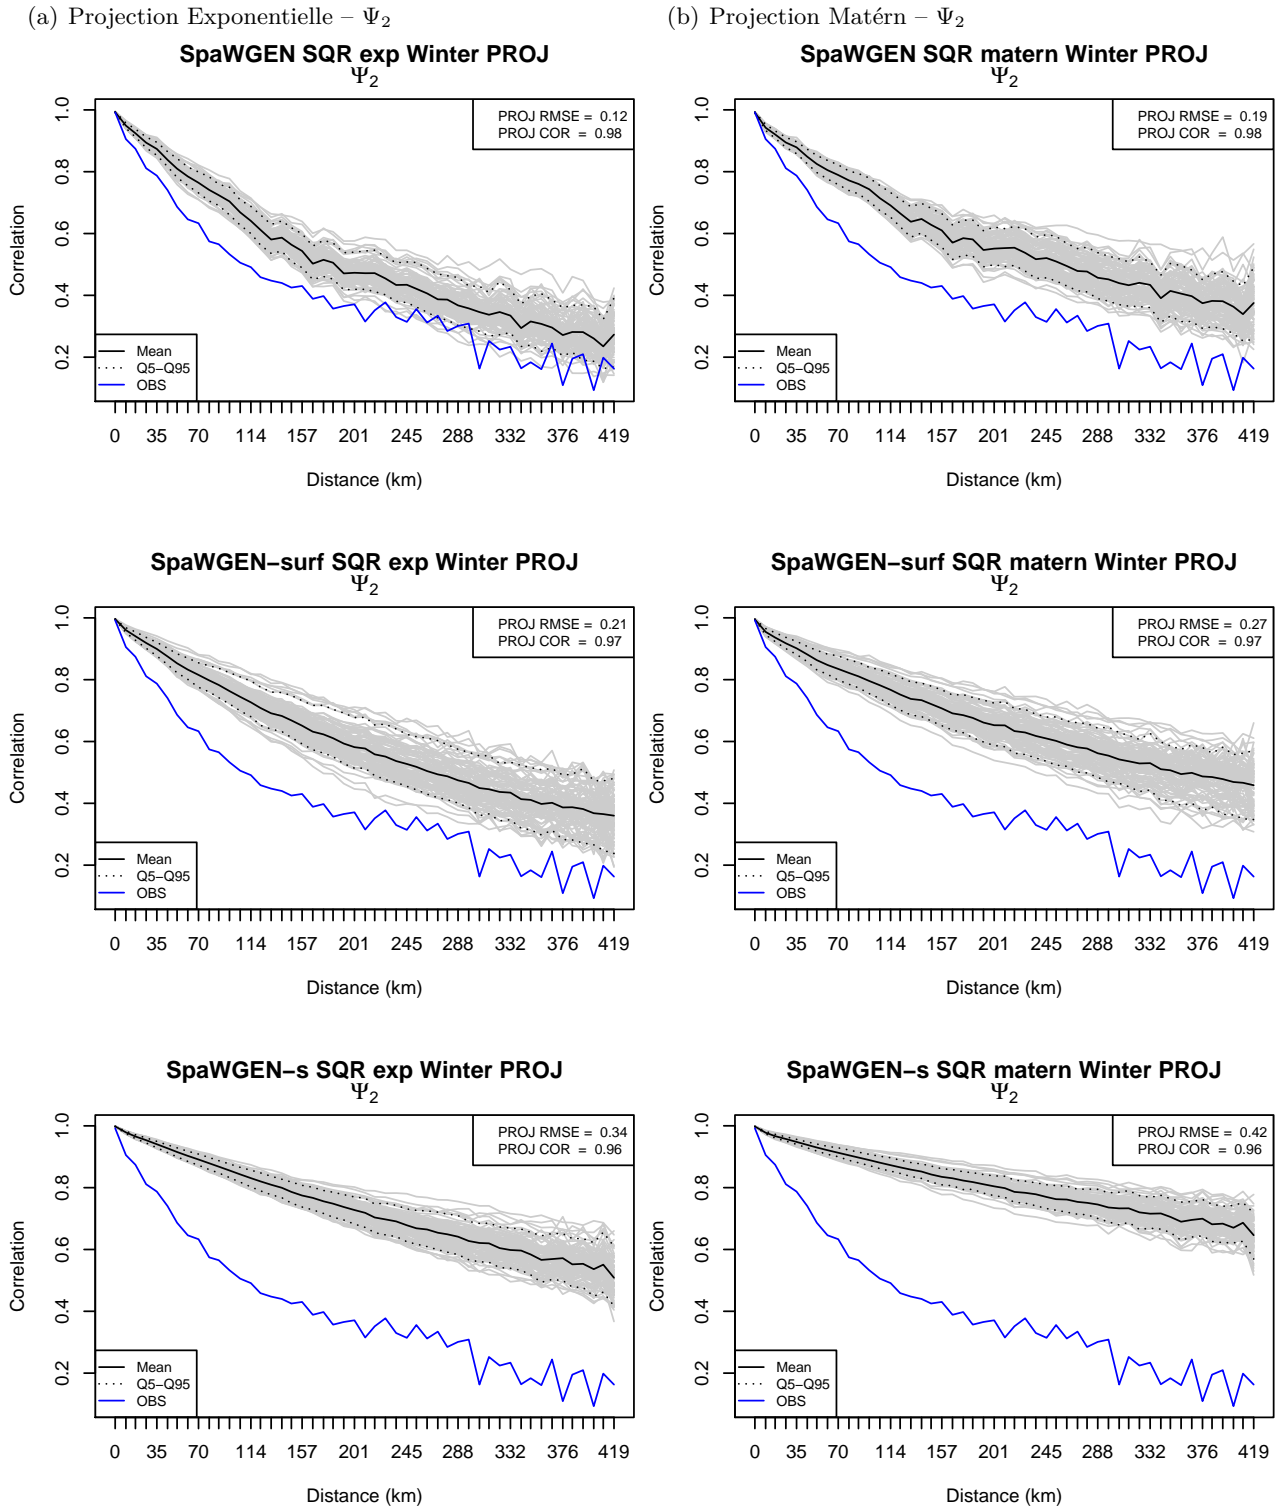


FIGURE IV.9 – Idem que précédemment pour l'anamorphose  $\Psi_2$ .

Les conclusions sont identiques pour toutes les saisons ainsi que pour la période de calibration. Quelle que soit l'anamorphose ou la fonction de covariance, la calibration SpaWGEN a un meilleur comportement que SpaWGEN-surf et SpaWGEN-s. En effet, d'après ce qui précède, les calibrations ont des résultats très similaires en ce qui concerne l'estimation de la probabilité d'occurrence. Pour ce qui est des propriétés marginales, SpaWGEN et SpaWGEN-surf sont très proches l'une de l'autre

alors que SpaWGEN-s est assez mauvaise en comparaison. C'est ensuite, grâce aux propriétés spatiale que l'on peut dire que SpaWGEN est meilleur que SpaWGEN-surf.

Ensuite, pour ce qui est des fonctions de covariance, la fonction de Matérn semble meilleure dans le cas de  $\Psi_1$  alors que la fonction exponentielle prend le dessus dans le cas de  $\Psi_2$ . Si on compare les anamorphoses c'est  $\Psi_2$  qui semble le plus à même de reproduire la corrélation spatiale des observations. Ces conclusions sont néanmoins plus compliquées qu'il n'y paraît. En effet, il faut préciser que l'anamorphose  $\Psi_1$  est tirée de VISCHEL et al. [2009]. Dans cette étude, la fonction de covariance est estimée directement à partir des précipitations et est ensuite normalisée par la variance pour en faire une fonction de covariance d'un processus gaussien dont les marginales ont une variance unitaire. Ceci avait été suggéré par GUILLOT [1999] comme étant une bonne approximation de l'expansion polynomiale qui y avait été utilisée. Le problème de cette approximation est qu'il n'y a aucune garantie que cela fonctionne dans notre cas puisque on ne peut dire qu'après simulation et au cas par cas si cela fonctionne ou non. Nous testerons cela dans la section SECTION 6. Dans notre cas nous voyons que la covariance est largement sous estimée. Ceci est une conséquence de la façon dont nous gérons les jours secs lorsque nous repassons dans le monde des précipitations, qui conduit à une perte d'une partie de la variabilité (ce que nous avons évoqué un peu plus haut). Pour ce qui est de  $\Psi_2$ , nous avons estimé la fonction de covariance en ajustant un processus gaussien à des valeurs tronquées en 0. Ceci peut expliquer le fait que nous surestimons la covariance dans le cas de  $\Psi_2$ . Nous estimons la fonction de covariance par maximum de vraisemblance (MV). L'emploi d'une méthode des moments (MM) peut potentiellement résoudre ce problème. En effet, DURBAN & GLASBEY [2001] ont montré que l'estimation par MV composite surestimait la covariance lorsque la dépendance de données, modélisées par une distribution gaussienne tronquée bivariée, est forte alors que cette méthode est relativement bonne lorsque les données présentent peu de dépendance. Ils ont également montré que la MM présentait un bon comportement quel que soit le type de dépendance dans les données.

Les résultats que l'on vient d'énoncer sont donc à considérer avec précaution.

Une autre métrique est utilisée pour étudier les propriétés spatiales des simulations : le logarithme de l'odds-ratio (log-odds ratio, LOR). L'odds ratio (OR, peut se traduire par "rapport des chances" en français) est une méthode de comptage qui se définit comme le rapport de la cote de deux variables binaires. La cote est le rapport entre le nombre de succès et le nombre d'échecs d'un événement. Dans notre cas, l'évènement est la présence(succès)/absence(échec) de pluie. Les deux variables binaires sont l'occurrence des précipitations à deux stations différentes. On note la présence de pluie à une station  $\mathbf{s}_i$  PP( $\mathbf{s}_i$ ) et l'absence NP( $\mathbf{s}_i$ ). On utilisera le logarithme de l'OR (LOR), et on ne cherchera pas à interpréter cette quantité mais à vérifier si les simulations présentent des valeurs proches de celles des observations. En pratique, nous allons le calculer à partir de la table de contingence suivante pour deux stations :

Tableau IV.2 – Table de contingence pour deux stations  $\mathbf{s}_i, \mathbf{s}_j$

	NP( $\mathbf{s}_i$ )	PP( $\mathbf{s}_i$ )
NP( $\mathbf{s}_j$ )	$n_{00}$	$n_{01}$
PP( $\mathbf{s}_j$ )	$n_{10}$	$n_{11}$

Le LOR se calcule de la façon suivante :

$$LOR = \log \left( \frac{n_{00}n_{11}}{n_{01}n_{10}} \right) \quad (\text{IV.21})$$

Les FIGURES IV.10 et IV.11 représentent les LORs des simulations en fonction de ceux des observations respectivement pour la période de calibration et de projection pour DJF. On peut voir que  $\Psi_1$  échoue totalement pour les deux périodes, pour les combinaisons de prédicteurs quelle que soit la fonction de covariance. Cela peut être expliqué de deux façons : lors de la transformation des observations nous générons pour chaque site des valeurs aléatoires entre  $[0, P_0]$  pour remplacer les 0 et pour assurer la normalité. Cela change complètement la cohérence spatiale par rapport à celle des observations. Ensuite, on brise une deuxième fois cette cohérence spatiale lorsqu'on passe dans le monde des précipitations pour les raisons évoquées pour le corrélogramme et la variabilité interannuelle.

$\Psi_2$  semble donner de meilleurs résultats mais surestime en partie les LORs. On peut expliquer cela de la même façon que pour le corrélogramme : l'estimation de la fonction de covariance se fait en ajustant un processus gaussien à des valeurs tronquées en 0 par MV. On obtient les LORs les plus proches de ceux des observations dans le cas de la calibration utilisant tous les prédicteurs (SpaWGEN). Pour les autres combinaisons de prédicteurs, la surestimation des LORs est plus importante et est plus forte pour SpaWGEN-s que pour SpaWGEN-surf. Les résultats sont très similaires pour les deux fonctions de covariance.

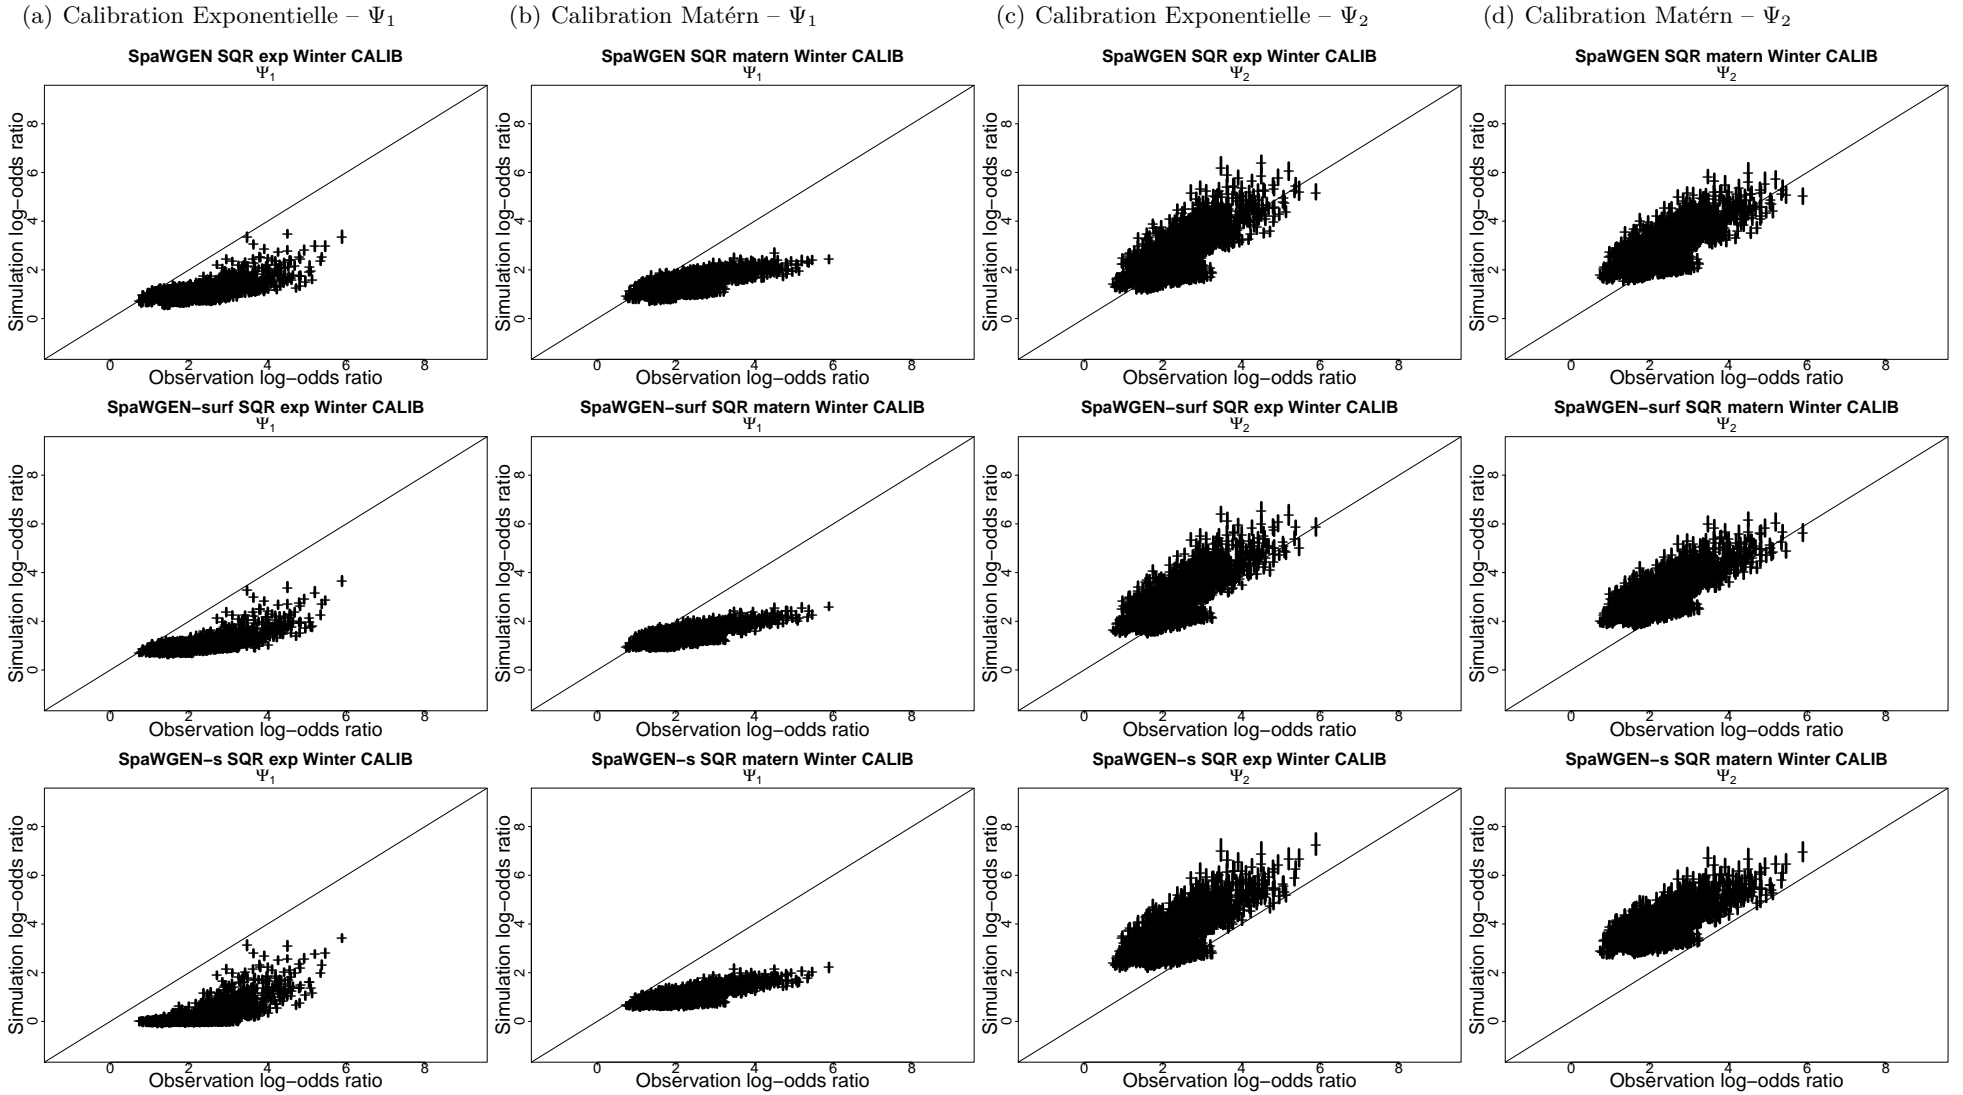


FIGURE IV.10 – Log-odds ratios (LORs) des simulations en fonction des LORs des observations pour DJF pour la période de calibration pour  $\Psi_1$  ((a) et (b)) et  $\Psi_2$  ((c) et (d)) et pour les fonctions de covariance exponentielle ((a) et (c)) et Matérn ((b) et (d)) et pour les trois calibrations. Les barres verticales représentent l'intervalle  $Q_5 - Q_{95}$  des LORs des simulations.



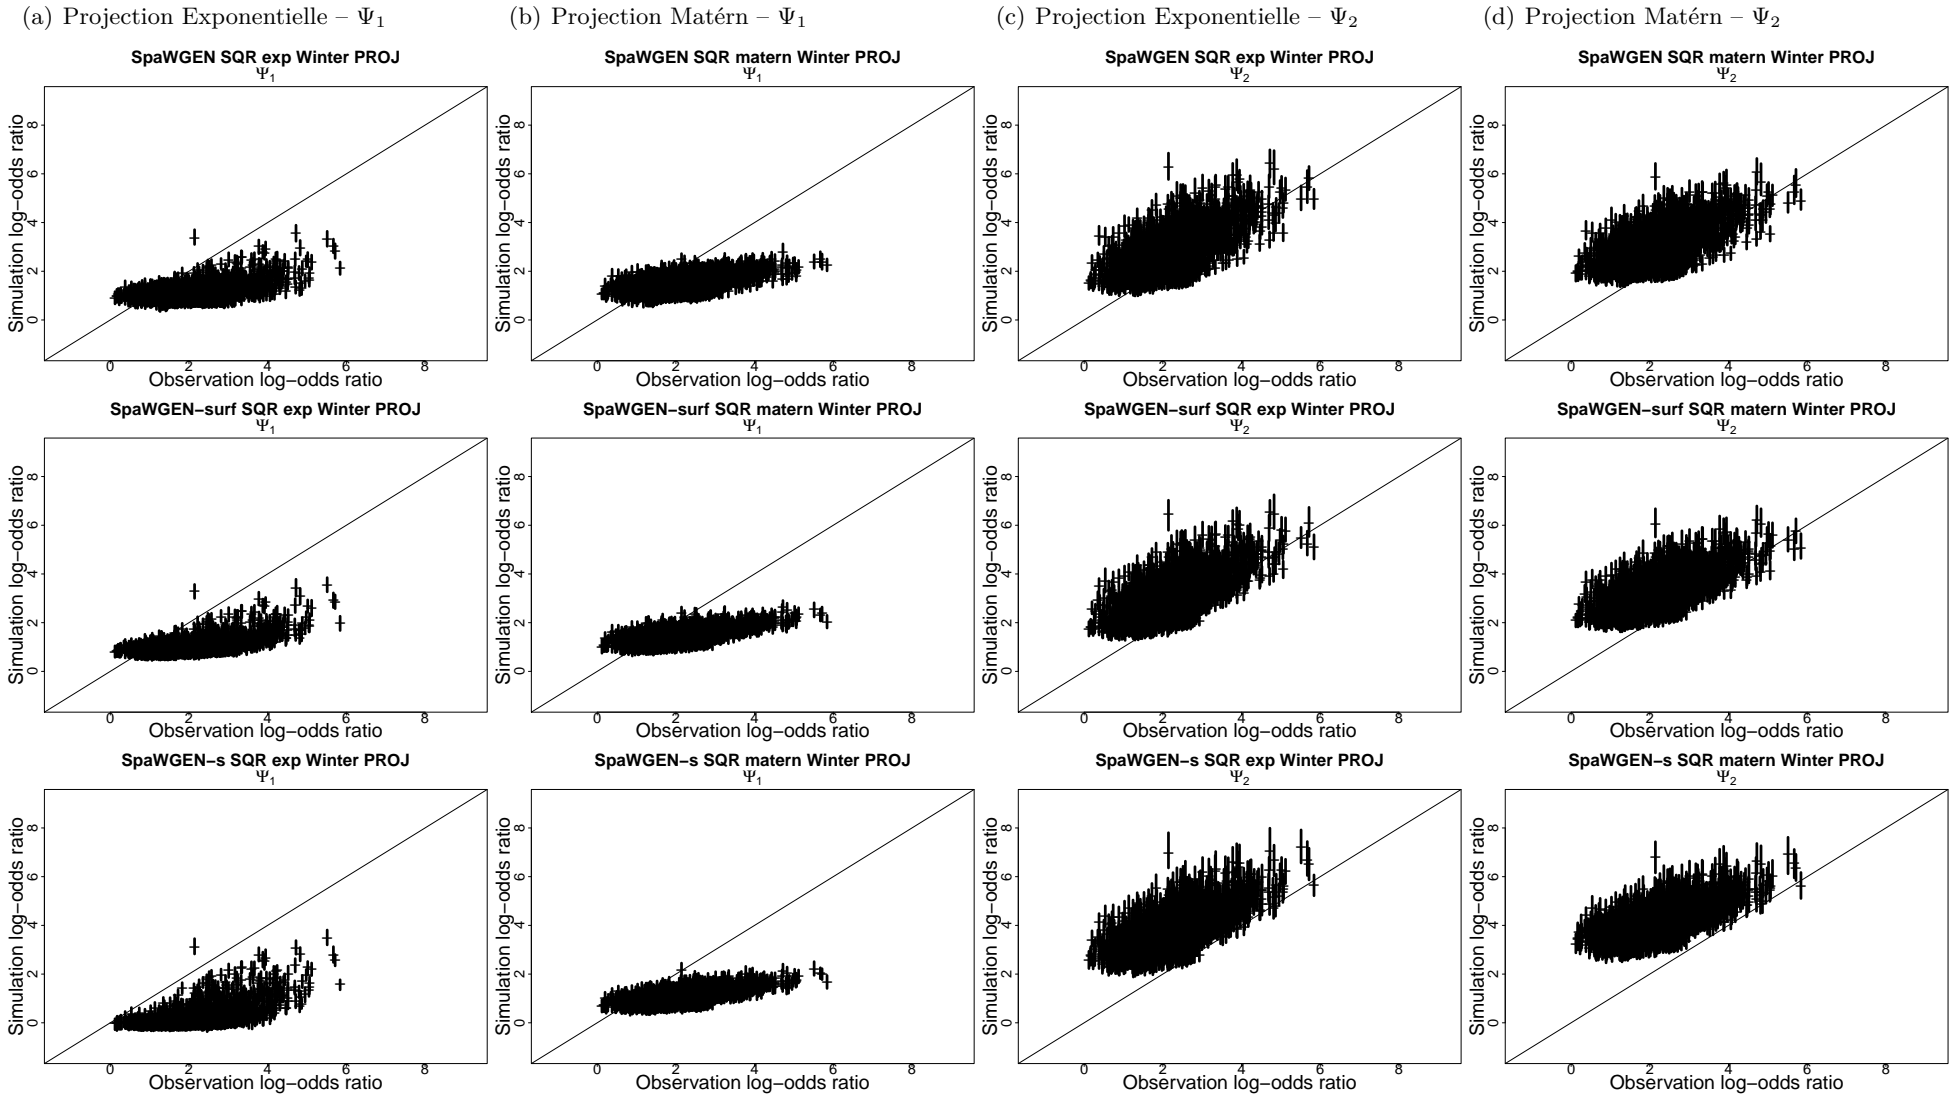


FIGURE IV.11 – Idem que précédemment pour la période de projection.

## 5.5. Covariance non-stationnaire

Nous avons vu à la SECTION 3.1 que notre volonté est d'introduire de la non-stationnarité dans le modèle ce qui a été fait dans la loi marginale. Nous souhaitons également introduire de la non-stationnarité dans sa fonction de covariance. L'anisotropie (ou non-stationnarité spatiale) peut être facilement introduite dans une fonction de covariance en utilisant une distance tenant compte de la directionnalité de la covariance du champ d'observations comme la distance de Mahalanobis :  $\tau(\mathbf{s}_i, \mathbf{s}_j) = \sqrt{(\mathbf{s}_i - \mathbf{s}_j)^T \Sigma^{-1} (\mathbf{s}_i - \mathbf{s}_j)}$ .  $\Sigma$  est une matrice définie positive, différente de la matrice identité qui donne la distance Euclidienne et donc l'isotropie. La non-stationnarité temporelle peut être introduite par l'utilisation de covariables dans l'estimation des paramètres de la fonction de covariance.

La covariance non-stationnaire que nous allons introduire est construite à partir d'une covariance anisotrope. HIGDON et al. [1999] ont introduit cette covariance non-stationnaire par la convolution de fonctions noyaux. PACIOREK & SCHERVISH [2006] ont généralisé le concept et énoncé le théorème suivant :

**Théorème IV.1** *Si une fonction de corrélation stationnaire isotrope,  $C^S(\tau)$ , est définie positive sur  $\mathbb{R}^d$  pour tout,  $d = 1, 2, \dots$ , alors la fonction  $C^{NS}(\cdot, \cdot)$  définie par :*

$$C^{NS}(\mathbf{s}_i, \mathbf{s}_j) = |\Sigma_i|^{\frac{1}{4}} |\Sigma_j|^{\frac{1}{4}} \left| \frac{\Sigma_i + \Sigma_j}{2} \right|^{-\frac{1}{2}} C^S(\sqrt{Q_{ij}}) \quad (\text{IV.22})$$

est une fonction de corrélation, définie positive sur  $\mathbb{R}^d$ ,  $d = 1, 2, \dots$ ,

avec  $Q_{ij}$  ayant la forme quadratique

$$Q_{ij} = (\mathbf{s}_i - \mathbf{s}_j)^T \left( \frac{\Sigma_i + \Sigma_j}{2} \right)^{-1} (\mathbf{s}_i - \mathbf{s}_j). \quad (\text{IV.23})$$

et  $\sqrt{Q_{ij}}$  remplace  $\tau$ . PACIOREK & SCHERVISH [2006] donne la forme non-stationnaire de la fonction de covariance de Matérn :

$$C_{\text{Matérn}}^{NS}(\mathbf{s}_i, \mathbf{s}_j) = \sigma^2 \frac{1}{\Gamma(\nu) 2^{\nu-1}} |\Sigma_i|^{\frac{1}{4}} |\Sigma_j|^{\frac{1}{4}} \left| \frac{\Sigma_i + \Sigma_j}{2} \right|^{-\frac{1}{2}} \left( 2\sqrt{\nu Q_{ij}} \right)^\nu K_\nu \left( 2\sqrt{\nu Q_{ij}} \right). \quad (\text{IV.24})$$

Par analogie nous avons la fonction de covariance exponentielle non-stationnaire suivante :

$$C_{\text{exp}}^{NS}(\mathbf{s}_i, \mathbf{s}_j) = \sigma^2 |\Sigma_i|^{\frac{1}{4}} |\Sigma_j|^{\frac{1}{4}} \left| \frac{\Sigma_i + \Sigma_j}{2} \right|^{-\frac{1}{2}} \exp \left( -\sqrt{Q_{ij}} \right). \quad (\text{IV.25})$$

$\Sigma_i = \Sigma(\mathbf{s}_i)$  est définie comme une matrice noyau locale centrée en  $\mathbf{s}_i$  et est une matrice symétrique définie positive. Afin de conserver une fonction de covariance définie positive les matrices  $\Sigma$  en deux localisations sont moyennées. En plus de l'anisotropie, du fait de l'évolution de  $\Sigma$  en fonction de la localisation, cette formulation permet à la fois l'introduction de la non-stationnarité temporelle dans la covariance grâce aux covariables temporelles. Ceci a entre autre motivé notre choix pour cette formulation.

En nous basant sur HUSER & GENTON [2014], une formulation possible des  $\Sigma_i$  est la suivante :

$$\Sigma_i = \begin{pmatrix} \omega_1^2(\mathbf{s}_i) & \omega_1(\mathbf{s}_i)\omega_2(\mathbf{s}_i)r(\mathbf{s}_i) \\ \omega_1(\mathbf{s}_i)\omega_2(\mathbf{s}_i)r(\mathbf{s}_i) & \omega_2^2(\mathbf{s}_i) \end{pmatrix} \quad (\text{IV.26})$$

Dans cet article, les paramétrisations ont la forme suivante :

$$\omega_1(\mathbf{s}) = \exp(\psi_{\omega_1}^0 + \boldsymbol{\psi}_{\omega_1} \mathbf{X}_{\omega_1}(\mathbf{s})), \quad \omega_2(\mathbf{s}) = \exp(\psi_{\omega_2}^0 + \boldsymbol{\psi}_{\omega_2} \mathbf{X}_{\omega_2}(\mathbf{s})), \quad \log\left(\frac{r(\mathbf{s}+1)}{2}\right) = \psi_r^0 + \boldsymbol{\psi}_r \mathbf{X}_r(\mathbf{s}).$$

$\mathbf{X}_{\omega_1}(\mathbf{s})$ ,  $\mathbf{X}_{\omega_2}(\mathbf{s})$  et  $\mathbf{X}_r(\mathbf{s})$  désignent des vecteurs de prédicteurs à la station  $\mathbf{s}$  et  $\boldsymbol{\psi}_{\omega_1}$ ,  $\boldsymbol{\psi}_{\omega_2}$  et  $\boldsymbol{\psi}_r$  les vecteurs de paramètres associées. Avec ces formulations, on s'assure que  $\omega_1(\mathbf{s}) > 0$ ,  $\omega_2(\mathbf{s}) > 0$  et  $r(\mathbf{s}) \in \{-1, 1\}$ .  $\omega_1(\mathbf{s})$  et  $\omega_2(\mathbf{s})$  sont les fonctions mesurant la portée de la corrélation à la station  $\mathbf{s}$  respectivement selon la direction 1 et 2 (classiquement selon l'axe  $x$  et  $y$ ) et  $r(\mathbf{s})$  capture l'anisotropie locale.

Nous testons le cas qualifié dans l'article de localement isotrope défini tel que  $r(\mathbf{s}) = 0$  et  $\omega_1(\mathbf{s}) = \omega_2(\mathbf{s}) = \exp(\psi^0 + \boldsymbol{\psi} \mathbf{X}(\mathbf{s}))$ .  $\mathbf{X}(\mathbf{s})$  représente d'une part l'ensemble des prédicteurs géographiques (nécessaires pour introduire l'anisotropie) et d'autre part les covariables temporelles. Ainsi, nous introduisons de la non-stationnarité spatiale et temporelle dans la fonction de covariance. Par cela, nous nous distinguons des études de PACIOREK & SCHERVISH [2006] et HUSER & GENTON [2014]. Nous pouvons écrire les formulations suivantes pour les deux fonctions de covariance :

$$C_{Matérn}^{NS}(\mathbf{s}_i, \mathbf{s}_j) = \sigma^2 \frac{\sqrt{2}}{\Gamma(\nu)2^{\nu-1}} \times \frac{\sqrt{\omega(\mathbf{s}_i)}\sqrt{\omega(\mathbf{s}_j)}}{\sqrt{\omega^2(\mathbf{s}_i) + \omega^2(\mathbf{s}_j)}} \left( \frac{2\sqrt{2\nu}\tau}{\sqrt{\omega^2(\mathbf{s}_i) + \omega^2(\mathbf{s}_j)}} \right)^\nu K_\nu \left( \frac{2\sqrt{2\nu}\tau}{\sqrt{\omega^2(\mathbf{s}_i) + \omega^2(\mathbf{s}_j)}} \right) \quad (\text{IV.27})$$

$$C_{exp}^{NS}(\mathbf{s}_i, \mathbf{s}_j) = \sigma^2 \frac{\sqrt{2}\sqrt{\omega(\mathbf{s}_i)}\sqrt{\omega(\mathbf{s}_j)}}{\sqrt{\omega^2(\mathbf{s}_i) + \omega^2(\mathbf{s}_j)}} \exp \left( \frac{-\sqrt{2}\tau}{\sqrt{\omega^2(\mathbf{s}_i) + \omega^2(\mathbf{s}_j)}} \right) \quad (\text{IV.28})$$

Comme évoqué à la SECTION 1, nous pouvons désormais introduire de la non-stationnarité spatiale et temporelle dans la fonction de covariance. Un premier test a été fait dans le cadre de l'anamorphose  $\Psi_2$  avec les deux fonctions de covariance dans leur version non-stationnaire dans le cas localement isotrope défini par les ÉQUATIONS IV.27 et IV.28 et uniquement pour la calibration SpaWGEN (*cf.* TABLEAU IV.1). Nous précisons pour les fonctions de covariance non-stationnaires (NS) qu'en plus des covariables spatiales, on utilisera uniquement la pression au niveau de la mer (MSL) et la hauteur du géopotential au niveau de pression de 850 hPa (Z850) comme covariables temporelles. Un travail plus élaboré doit être réalisé quant au choix de ces variables mais nous nous contenterons de cela dans un premier temps. Nous allons reproduire quelques unes des figures précédentes pour ces cas afin de caractériser l'apport de la non-stationnarité spatio-temporelle. La FIGURE IV.12 représente la variabilité interannuelle pour  $\Psi_2$  avec les deux fonctions de covariance NS. Si on compare ces simulations à leurs équivalents ayant une covariance stationnaire (*cf.* FIGURES IV.5(b) et IV.6(b)), les différences sont minimales.

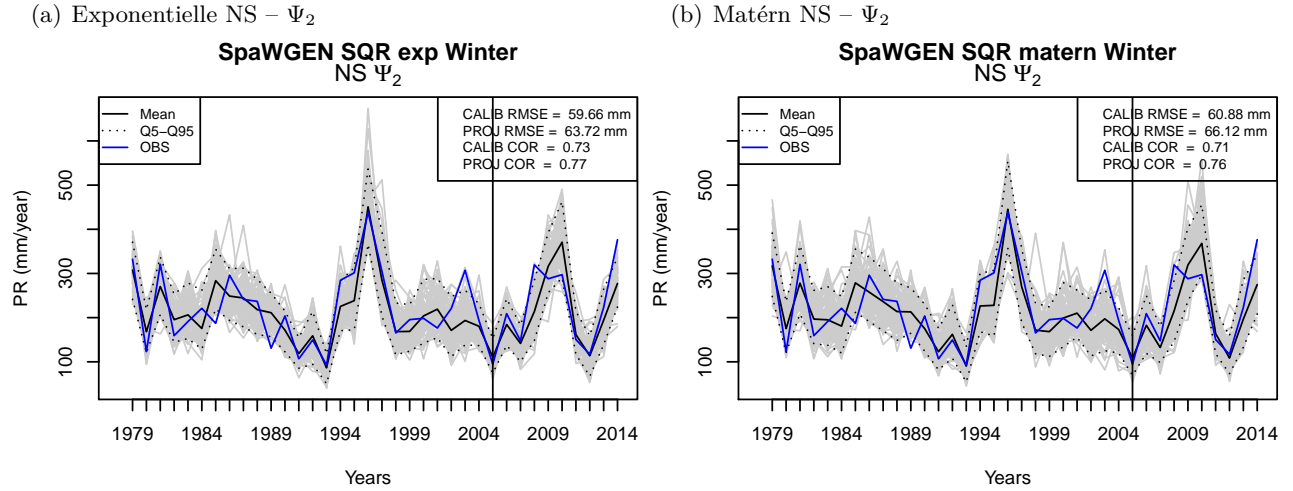


FIGURE IV.12 – Variabilité interannuelle (idem FIGURES IV.5(b) et IV.6(b)) pour  $\Psi_2$  avec les fonctions de covariance exponentielle et de Matérn non-stationnaires dans le cas SpaWGEN.

Regardons maintenant le cycle saisonnier des simulations pour  $\Psi_2$  avec les deux fonctions de covariance NS à la FIGURE IV.13.

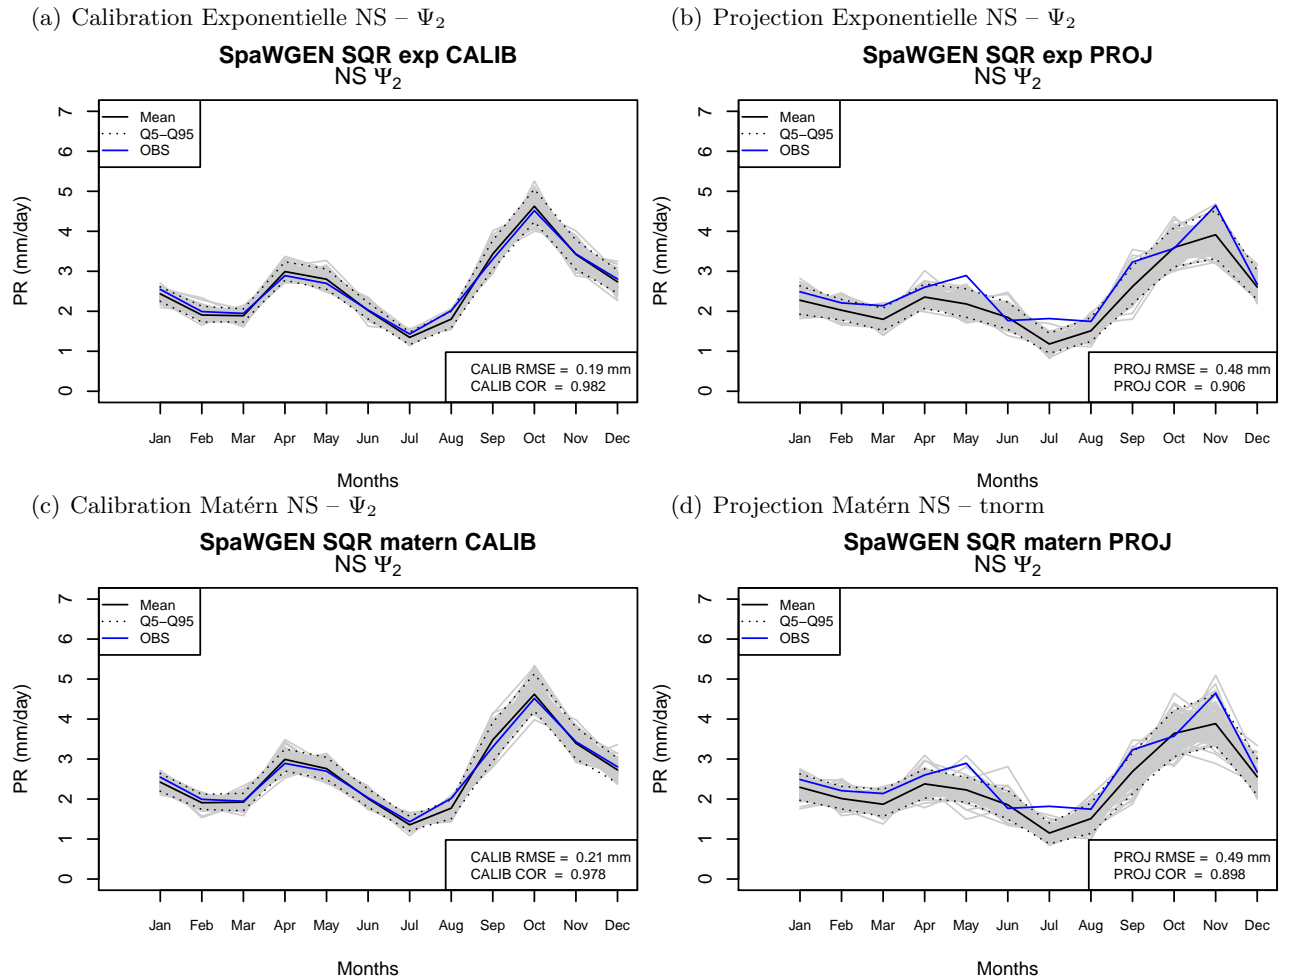


FIGURE IV.13 – Cycle saisonnier (idem FIGURES IV.7(c) et IV.7(d)) pour  $\Psi_2$  avec les fonctions de covariance exponentielle et de Matérn non-stationnaires dans le cas SpaWGEN.

Encore une fois, si on compare ces simulations avec les simulations équivalentes ayant une covariance stationnaire, la différence est très faible. Nous nous intéressons ensuite aux corrélogrammes présentés à la FIGURE IV.14.

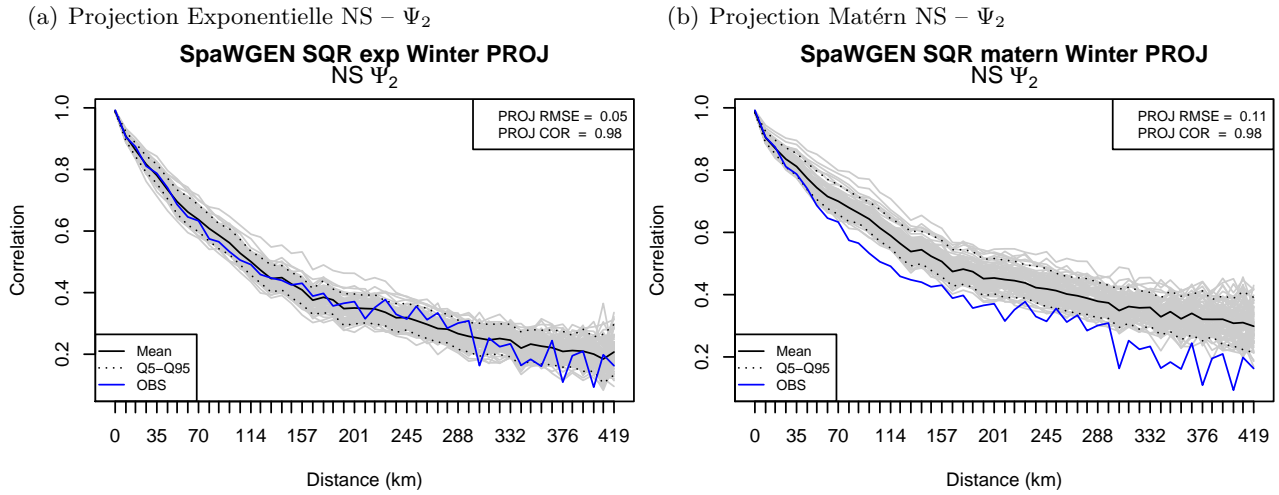


FIGURE IV.14 – Corrélogramme (idem FIGURE IV.9) pour  $\Psi_2$  avec les fonctions de covariance exponentielle et de Matérn non-stationnaire dans le cas SpaWGEN.

On constate ici une nette amélioration en termes de corrélogramme des simulations par rapport aux simulations avec une covariance stationnaire (*cf.* FIGURE IV.9). On reste cohérent avec le cas stationnaire où la fonction de covariance exponentielle est plus performante dans le cas de  $\Psi_2$ . Dans le cas d'une covariance non-stationnaire on constate un excellent comportement de la fonction exponentielle : le corrélogramme des observations est contenu dans l'enveloppe des corrélogrammes de la fonction exponentielle. Le dernier aspect considéré ici est le LOR représenté à la FIGURE IV.15.

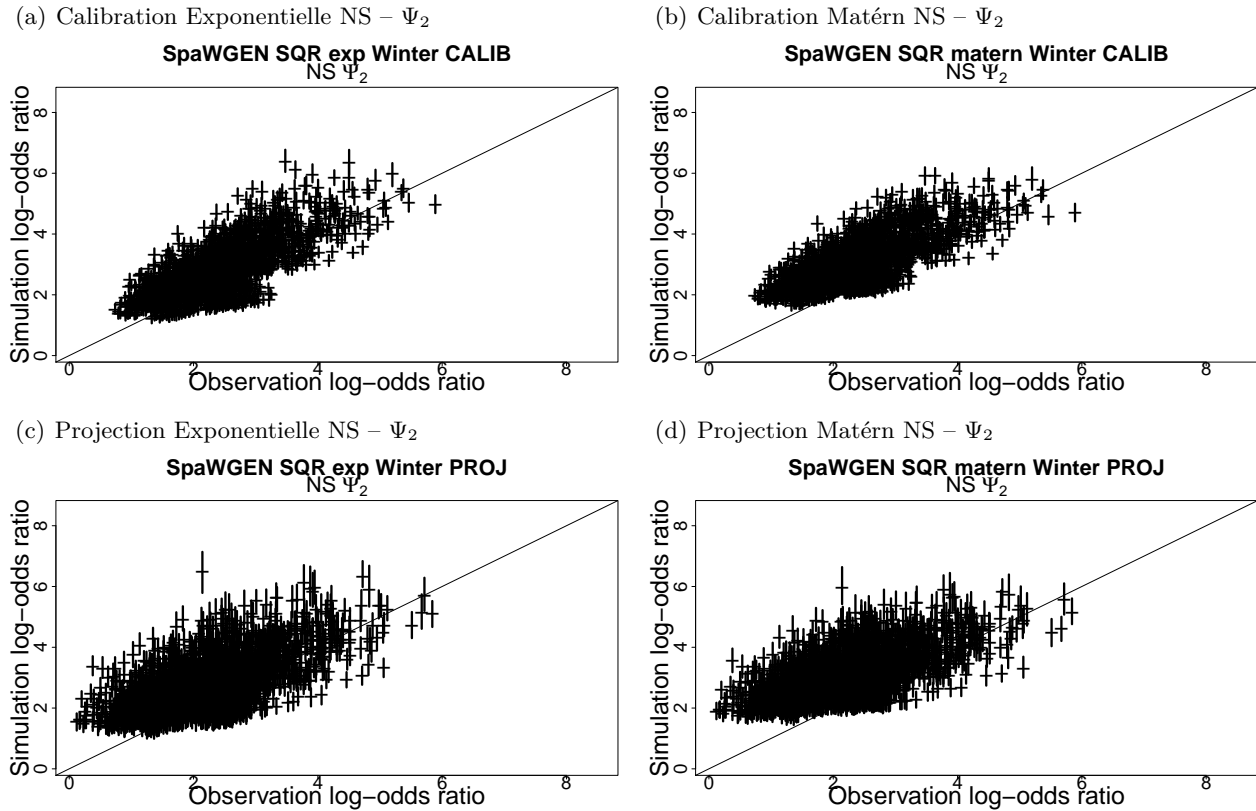


FIGURE IV.15 – LORs (idem FIGURES IV.10(c), IV.10(d), IV.11(c), IV.11(d)) pour  $\Psi_2$  avec les fonctions de covariance exponentielle et de Matérn non-stationnaire dans le cas SpaWGEN.

Ces figures montrent des résultats similaires aux simulations avec des fonctions de covariance stationnaires.

Ces analyses montrent clairement la valeur ajoutée d'une covariance non-stationnaire telle qu'elle a été appliquée ici. L'objectif premier d'une telle fonction de covariance est d'obtenir une nette amélioration du point de vue du corrélogramme. Cet objectif est clairement atteint. Cela nous permet de démontrer l'apport d'une fonction de covariance non-stationnaire même si il n'y a pas de progrès du point de vue des propriétés marginales et des LORs. Nous avons montré ici la faisabilité et le potentiel d'une telle approche même si il reste un travail à faire du point de vue des covariables incorporées dans la fonction de covariance. Il faudra éventuellement sortir du cadre localement isotrope testé ici.

## 6. Conclusions et perspectives

Dans ce chapitre nous avons établi les bases pour le développement d'un nouveau modèle spatial de downscaling. Les deux aspects principaux à avoir été testés sont : (i) l'utilisation d'un seul processus gaussien latent dans la modélisation spatiale des précipitations dans un contexte de modèle de réduction d'échelle statistique et donc temporellement non-stationnaire et (ii) l'apport des covariables spatiales et temporelles pour l'estimation des paramètres de la distribution marginale d'une part et de la fonction de covariance d'autre part. Nous avons pour ce faire testé respectivement deux anamorphoses – sus-nommées  $\Psi_1$  et  $\Psi_2$  – en les combinant à deux fonctions de covariance – l'exponentielle et la fonction de Matérn et – en utilisant trois calibrations combinant différents prédicteurs pour l'estimation de la fonction marginale :

- SpaWGEN : X, Y, Z, D2, MSL, T2, U850, V850 et Z850,
- SpaWGEN-surf : X, Y, Z, D2, MSL, T2,
- SpaWGEN-s : X, Y, Z.

Nous avons effectué 14 ensembles de 100 simulations sur la période 1979-2014 (*cf.* TABLEAU IV.1).

Nous avons d'abord évalué la fréquence de jours de pluie (*cf.* SECTION 5.2). Il s'avère que l'estimation de cette fréquence présente des biais assez importants, positifs ou négatifs, quelle que soit la calibration. Du point de vue des propriétés marginales (*cf.* SECTION 5.3), quelle que soit la simulation, elle présente une variabilité du biais moyen assez importante. En terme de variabilité interannuelle et de cycle saisonnier, il y a très peu de différence entre l'emploi des deux fonctions de covariance. L'anamorphose  $\Psi_2$  génère plus de variabilité que  $\Psi_1$ , la variabilité des observations est ainsi mieux appréhendée dans le premier cas que dans le second. De plus, l'introduction de covariables temporelles se révèle très intéressante pour générer la variabilité interannuelle et saisonnière. On observe en effet que la calibration SpaWGEN-s (i.e. sans covariables temporelles) ne présente pas de différence de variabilité d'une année sur l'autre ou de changement de cycle saisonnier entre la période de calibration et de projection. Enfin du point de vue spatial (*cf.* SECTION 5.4), quelle que soit la calibration et la fonction de covariance, les simulations utilisant  $\Psi_1$  ont tendance à sous estimer la covariance et les LORs par rapport à celles des observations alors que  $\Psi_2$  surestime la covariance et les LORs.

L'introduction de la non-stationnarité spatio-temporelle dans la fonction de covariance a uniquement été testée dans le cas de  $\Psi_2$  avec la calibration SpaWGEN. On observe un net gain de performance en terme de corrélogramme, ce qui était le but recherché. Les autres aspects de ces simulations sont similaires aux simulations ayant des fonctions de covariance stationnaires. Finalement, il semble que la meilleur combinaison pour l'instant soit l'anamorphose  $\Psi_2$  avec une covariance exponentielle non-stationnaire et avec une calibration SpaWGEN. En ce qui concerne  $\Psi_1$ , il faut rappeler que dans VISCHÉL et al. [2009] la fonction de covariance est estimée directement à partir des précipitations et est ensuite normalisée par la variance pour l'utiliser dans le cas d'un processus gaussien donc les marginales ont une variance unitaire. Nous avons réalisé une seule simulation avec la fonction de covariance de Matérn avec la calibration SpaWGEN à titre de test et voici quelques graphiques permettant de jauger l'efficacité de ce modèle.

Les FIGURES IV.16 et IV.17 représentent respectivement la variabilité interannuelle et le cycle saisonnier de cette simulation. Il semble que pour le cycle saisonnier, le résultat soit équivalent à toutes les autres simulations alors que la variabilité interannuelle semble sous-estimée.




FIGURE IV.16 – Variabilité interannuelle hivernale pour  $\Psi_1$  avec une fonction de covariance Matérn calibrée à partir des observations.




FIGURE IV.17 – Cycle saisonnier pour  $\Psi_1$  avec une fonction de Matérn covariance calibrée à partir des observations.

Ensuite, les FIGURES IV.18 et IV.19 représentent respectivement le corrélogramme et les LORs. On constate une nette amélioration en terme de corrélogramme et de LORs par rapport aux autres simulations réalisées dans le cadre de  $\Psi_1$  même si on constate une légère sous-estimation. Avec une fonction de covariance estimée à partir des observations  $\Psi_1$  semble considérablement s'améliorer. Il reste à réaliser les 100 simulations pour en déduire des conclusions plus robustes et à court terme cette option pourrait s'avérer performante. L'estimation à partir des observations permet de garder la structure spatiale des observations lorsque l'on simule le champ gaussien. L'utilisation d'une covariance non-stationnaire pourrait se révéler plus efficace dans ce contexte.




FIGURE IV.18 – Corrélogramme hivernal pour  $\Psi_1$  avec une fonction de Matérn calibrée à partir des observations.

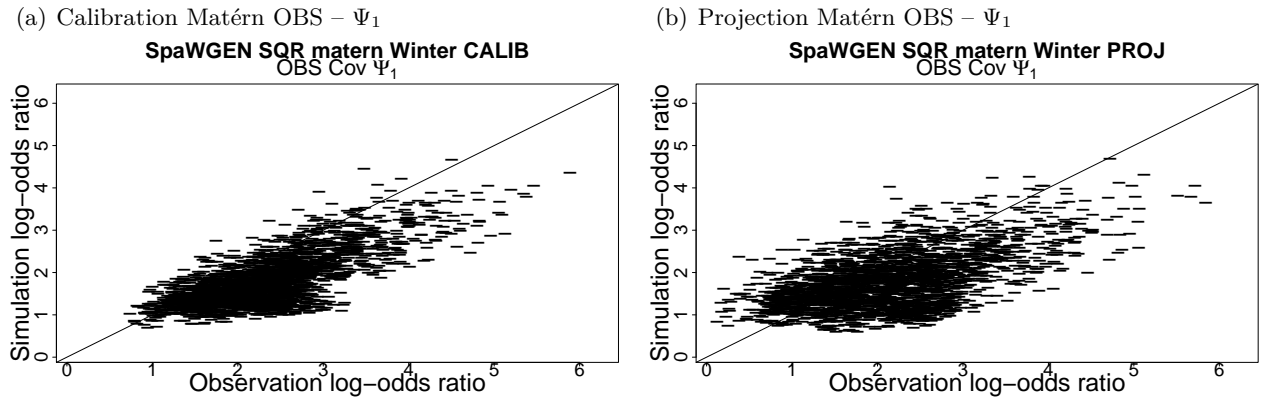


FIGURE IV.19 – LORs hivernaux pour  $\Psi_1$  avec une fonction de Matérn calibrée à partir des observations.

## Mise en garde

Que ce soit pour  $\Psi_1$  ou  $\Psi_2$  un point se doit d'être signaler. En effet, pour des raisons de simplicité les paramètres de la distribution marginales et de la fonction de covariance sont estimés séparément pour ces modèles à une seule variable latente gaussienne. En faisant cela, on suppose que la transformation et donc la valeur de la variable latente en un point sec est déterministe et indépendante de sa position dans le champs ainsi que des valeurs aux autres points du champs. Or, il est souhaitable que toutes les valeurs du processus gaussien sous-jacent inférieures au seuil d'occurrence des précipitations soient tirées de façon conjointe. En effet, la position et la valeur des pluies non-nulles jouent un rôle puisque



les deux processus (occurrence et intensité) ont été choisis intriqués, de même que le variogramme prêté au processus gaussien sous-jacent.

Pour réaliser cela, il sera nécessaire d'avoir recours à un algorithme de Gibbs ou de Metropolis-Hastings et d'estimer tous les paramètres en une seule fois. Cette procédure pourra être assez coûteuse et devra être réalisée au moins à titre de comparaison, dans un objectif de publication.

## Quelques Perspectives

Dans la suite, nous allons discuter certaines des options de simulations utilisées et esquisser certaines alternatives et perspectives.

### *Perspectives concernant la loi marginale*

Dans ce chapitre de développement, nous avons adopté le cadre le formalisme des modèles linéaires généralisé (GLM) pour introduire des covariables spatiales et temporelles dans l'estimation des paramètres de la distribution marginale, c'est-à-dire que nous avons fait l'hypothèse que le lien entre prédicteurs et prédicands est linéaire. On peut se demander si cela est vraiment le cas. Pour vérifier cela, nous avons refait la régression logistique et estimé à nouveau les paramètres de distribution  $\gamma_{\alpha,\beta}$  dans un contexte de modèle additif généralisé [GAM, HASTIE & TIBSHIRANI, 1990]. Dans le contexte GAM, la régression logistique de l'ÉQUATION IV.14 prend la forme suivante :

$$\log \left( \frac{p(\mathbf{s}, t)}{1 - p(\mathbf{s}, t)} \right) = P^0 + \sum_{j=1}^N P^j f_j (X_j(\mathbf{s}, t)), \quad (\text{IV.29})$$

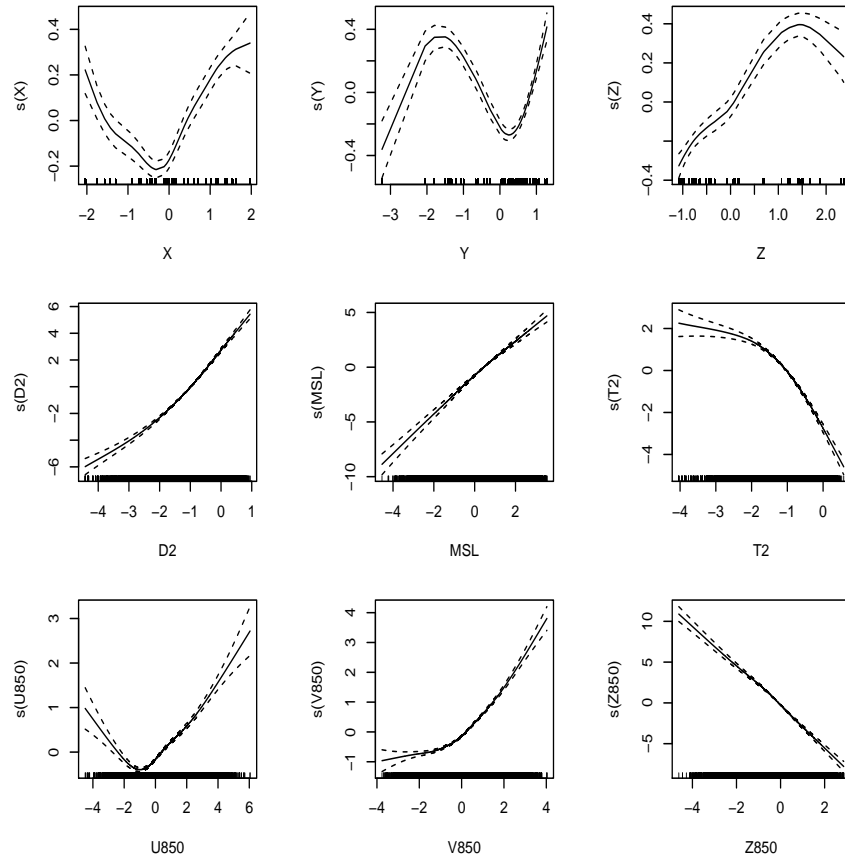
et l'ÉQUATION IV.13 devient

$$\begin{cases} \log(\alpha(\mathbf{s}, t)) &= \alpha^0 + \sum_{j=1}^N \alpha^j f_j (X_j(\mathbf{s}, t)), \\ \log(\beta(\mathbf{s}, t)) &= \beta^0 + \sum_{j=1}^N \beta^j f_j (X_j(\mathbf{s}, t)), \end{cases} \quad (\text{IV.30})$$


où  $f_j$  sont des splines cubiques de régression.

La FIGURE IV.20 suivante donne les splines en question pour chacune des trois calibrations pour le mois de janvier (rappel : les modèles ont été calibrés de façon mensuelle). Elle montre clairement des dépendances non-linéaires entre prédicteurs et prédicands dans les trois cas pour les prédicteurs géographiques. Les prédicteurs temporels ont un comportement quasi-linéaire tout au moins sur une partie de leur domaine et sont monotones (croissants ou décroissants) dans tous les cas excepté U850 dans le cas SpaWGEN. A partir d'une calibration faite pour les paramètres de distribution  $\gamma_{\alpha,\beta}$ , les FIGURES IV.21 et IV.22 montrent les splines de régressions issues de l'estimation des paramètres pour le mois de janvier. Que ce soit pour  $\alpha$  ou  $\beta$ , les liens des deux paramètres avec les prédicteurs sont globalement non-linéaires pour l'ensemble des trois calibrations.

(a) SpaWGEN



(b) SpaWGEN-surf



(c) SpaWGEN-s


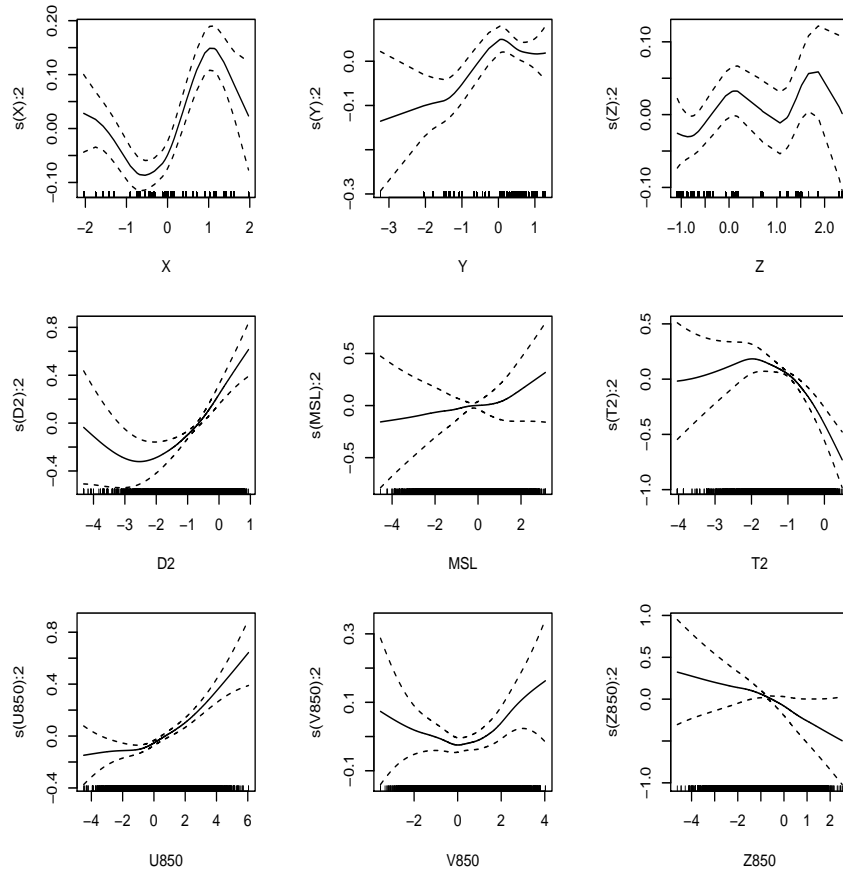



FIGURE IV.20 – Splines de la régression logistique de chaque calibration : (a) SpaWGEN, (b) SpaWGEN-surf, (c) SpaWGEN-s pour le mois de janvier.

(a) SpaWGEN



(b) SpaWGEN-surf



(c) SpaWGEN-s






FIGURE IV.21 – Splines de régressions de chaque calibration : (a) SpaWGEN, (b) SpaWGEN-surf, (c) SpaWGEN-s pour le mois de janvier lors de l'estimation du paramètre de forme  $\alpha$  de la distribution  $\gamma$ .


(a) SpaWGEN



(b) SpaWGEN-surf



(c) SpaWGEN-s

FIGURE IV.22 – Idem que la FIGURE IV.21 pour le paramètre d'intensité  $\beta$  de la distribution  $\gamma$ .

On peut ainsi expliquer certaines lacunes des modèles précédents. En effet, nous avons constaté sur la FIGURE IV.3 un biais relativement important dans l'estimation de la fréquence de jours de pluie. Ceci est sans doute dû à l'utilisation d'un GLM dans son estimation. Nous pouvons expliquer de la même façon les biais moyens importants de la FIGURE IV.4 par l'estimation des paramètres de la distribution  $\gamma_{\alpha,\beta}$  par un GLM. Un autre constat est que si on considère la FIGURE IV.6, SpaWGEN-surf s'adapte mieux à un changement du cycle que SpaWGEN. Il se peut qu'avec plus de prédictors présentant une dépendance non-linéaire aux paramètres, comme c'est le cas de SpaWGEN par rapport à SpaWGEN-surf, un modèle ajusté dans un cadre GLM présente des biais plus importants dans ses paramètres estimés. Cette non-linéarité peut également attester d'un choix d'une région d'étude trop grande avec des climats très différents (e.g. influences orographiques et maritimes). Une réduction de la région peut être envisagée. Néanmoins, le but de ce modèle étant de modéliser cette hétérogénéité climatique, on a plutôt intérêt à travailler sur les prédictors permettant une meilleure représentation de cette non-stationnarité climatique. L'utilisation d'un modèle additif généralisé (GAM) semble plus à propos et ceci amène une piste d'amélioration à court terme pour le modèle.

Ensuite, intéressons-nous au choix de la loi marginale : notre choix s'est porté sur la distribution gamma du fait de sa flexibilité, mais celle-ci n'est pas adaptée pour modéliser les fortes valeurs de précipitations [KLEIBER et al., 2012]. Nous avons fait un test avec une distribution de Pareto généralisée (GPD). La GPD a été utilisée dans BOUVIER et al. [2003] mais le seuil d'occurrence des précipitations y était fixé à 5mm. Notre test pour un seuil de 0mm s'avère peu satisfaisant puisque ce seuil trop bas génère une GPD avec une queue de distribution très lourde et des valeurs extrêmement fortes et absolument pas réalistes (on ne le montrera pas ici). Une solution serait d'utiliser un mélange de distributions entre une gamma et une GPD [e.g. VRAC & NAVEAU, 2007 ; CARREAU & VRAC, 2011 ; BAXEVANI & LENNARTSSON, 2015]. Une autre solution à cela semble être apportée dans NAVEAU et al. [2015], où une reparamétrisation d'une GPD (GPD étendue) a été développée afin de modéliser aussi bien les faibles cumuls que les valeurs extrêmes des précipitations sans mélange de distributions.

### *Perspectives concernant les variables*

Nous avons choisi les stations de calibration/validation en fonction de la latitude. On pourrait faire ce choix par exemple en fonction des cumuls annuels ou de l'isolement géographique des stations.

Un effort doit également être porté quant aux choix des prédictors atmosphériques que ce soit pour la marginale et la fonction de covariance. Prendre uniquement, pour une station donnée, les prédictors de la maille grande échelle qui contient la station fait que nous manquons forcément une grande partie de l'information à grande échelle concernant la circulation atmosphérique ainsi que l'influence maritime et orographique sur elle.

### *Perspectives concernant la fonction de covariance non-stationnaire*

Comme évoqué à la SECTION 5.4, il serait bon de vérifier si l'estimation de la fonction de covariance par MV biaise son estimation dans le cas de  $\Psi_2$  en l'estimant à nouveau par une méthode des moments dans le cas stationnaire et dans le cas non-stationnaire.

Dans le cas de  $\Psi_1$ , il reste à tester la covariance non-stationnaire dans le cas où elle est estimée à partir des observations puis ensuite normalisée [VISCHEL et al., 2009].

### *Perspective à plus long terme*

Nous rappelons que la calibration a été faite de façon mensuelle afin de tenir compte de la saisonnalité. Une utilisation de régimes saisonniers de précipitations permettrait de passer de douze calibrations mensuelles à quatre saisonnières. Les régimes seraient définis en utilisant une méthodologie similaire à celle employée au CHAPITRE V. Dans ce chapitre, nous donnons une définition de régimes de circulation saisonniers. Nous pourrions également déterminer des régimes intra-saisonniers en se basant sur la même méthodologie. Ceci nous permettrait non seulement une compréhension plus fine des structures grande échelle provoquant les précipitations et également des structures de précipitations plus fines à l'échelle locale.

Une évaluation et une application du modèle dans un contexte de changement climatique est également une perspective intéressante. Ceci est potentiellement possible grâce aux composantes du modèle qui sont non-stationnaires (marginale et fonction de covariance).

À plus long terme, on peut envisager le développement d'un modèle spatial de downscaling multivariable modélisant de manière cohérente plusieurs variables physiques en même temps [e.g. précipitations et températures FLECHER et al., 2010]. La cohérence inter-variable est notamment importante dans la perspective de modèles d'impacts qui requièrent une bonne cohérence entre les variables physiques fournies en entrée. Dans le cas contraire, des variables simulées séparément peuvent potentiellement provoquer des situations qui ne sont pas réalistes [WHITE & TOUMI, 2013].

## 7. Synthèse des résultats

Dans ce chapitre, nous présentons les étapes successives du processus de développement d'un modèle spatial de downscaling statistique des précipitations. Le travail est réalisé à partir d'observations issues des séries quotidiennes de référence de Météo France et des prédicteurs à grande échelle issue de la base de données ERA-interim.

Le travail est mené dans le cadre des processus méta-gaussiens. Nous avons pour objectif de développer un modèle non-stationnaire du point de vue spatial et temporel. Pour cela, nous souhaitons introduire cette non-stationnarité à la fois dans la distribution marginale en se plaçant dans un cadre de modèle linéaire généralisé (GLM) et dans la fonction de covariance.

Dans ce chapitre, nous testons plusieurs options de modélisation. Pour cela, nous avons combiné :

- i. deux paramétrisations différentes du processus méta-gaussien,
- ii. deux fonctions de covariance (Matérn et exponentielle) dans leurs versions stationnaires et non-stationnaires,
- iii. trois combinaisons de prédicteurs pour l'estimation des paramètres de la distribution marginale grâce à un GLM.

Ainsi, nous obtenons 14 combinaisons pour lesquelles 100 simulations sont exécutées sur la période 1979-2014 et comparées du point de vue de l'occurrence, l'intensité et des propriétés spatiales des précipitations.

Les travaux menés permettent de mettre en évidence l'apport des covariables temporelles dans la modélisation spatiale et les résultats sont très encourageants.

Il reste néanmoins quelques améliorations à apporter, réalisables à court terme, notamment concernant le choix des prédicteurs et le remplacement du GLM par un modèle additif généralisé (GAM).

## Références Bibliographiques du Chapitre IV

- ADLER, R. J. [1981]. “The Geometry of Random Fields.” Wiley, Chichester.
- AILLIOT, Pierre, THOMPSON, Craig & THOMSON, Peter [2009]. “Space-time modelling of precipitation by using a hidden Markov model and censored Gaussian distributions”. *Journal of the Royal Statistical Society : Series C (Applied Statistics)*. Vol. 58. no. 3, p. 405–426.
- AILLIOT, Pierre, ALLARD, Denis, MONBET, Valérie & NAVEAU, Philippe [2015]. “Stochastic weather generators : an overview of weather type models”. *Journal de la Société Française de Statistique*. Vol. 156. no. 1, p. 101–113.
- ALLARD, Denis & BOUROTTE, Marc [2015]. “Disaggregating daily precipitations into hourly values with a transformed censored latent Gaussian process”. *Stochastic Environmental Research and Risk Assessment*. Vol. 29. no. 2, p. 453–462.
- AMBROSINO, Chiara, CHANDLER, Richard E. & TODD, Martin C. [2014]. “Rainfall-derived growing season characteristics for agricultural impact assessments in South Africa”. *Theoretical and Applied Climatology*. Vol. 115. no. 3-4, p. 411–426.
- BARDOSSY, Andras & PLATE, Erich J. [1992]. “Space-time model for daily rainfall using atmospheric circulation patterns”. *Water Resources Research*. Vol. 28. no. 5, p. 1247–1259.
- BAXEVANI, Anastassia & LENNARTSSON, Jan [2015]. “A spatiotemporal precipitation generator based on a censored latent Gaussian field”. *Water Resources Research*. Vol. 51. no. 6, p. 4338–4358.
- BELL, Thomas L. [1987]. “A space-time stochastic model of rainfall for satellite remote-sensing studies”. *Journal of Geophysical Research : Atmospheres*. Vol. 92. no. D8, p. 9631–9643.
- BELLONE, Enrica, HUGHES, James P. & GUTTORP, Peter [2000]. “A hidden Markov model for downscaling synoptic atmospheric patterns to precipitation amounts”. *Journal of Hydrology*. Vol. 15. no. 1, p. 1–12.
- BILLINGSLEY, Patrick [2008]. “Probability and measure”. John Wiley & Sons, 3rd Ed., New York.
- BOUVIER, Christophe, CISNEROS, Leonardo, DOMINGUEZ, Ramon, LABORDE, Jean-Pierre & LEBEL, Thierry [2003]. “Generating rainfall fields using principal components (PC) decomposition of the covariance matrix : a case study in Mexico City”. *Journal of Hydrology*. Vol. 278. no. 1–4, p. 107–120.
- BUISHAND, T. Adri & BRANDSMA, Theo [2001]. “Multisite simulation of daily precipitation and temperature in the Rhine Basin by nearest-neighbor resampling”. *Water Resources Research*. Vol. 37. no. 11, p. 2761–2776.
- BURTON, A., KILSBY, C.G., FOWLER, H.J., COWPERTWAIT, P.S.P. & O’CONNELL, P.E. [2008]. “RainSim : A spatial-temporal stochastic rainfall modelling system”. *Environmental Modelling & Software*. Vol. 23. no. 12, p. 1356–1369.
- CARREAU, Julie & VRAC, Mathieu [2011]. “Stochastic downscaling of precipitation with neural network conditional mixture models”. *Water Resources Research*. Vol. 47. no. 10. W10502, n/a–n/a.
- CHANDLER, R. E. [2002]. “GLIMCLIM : generalized linear modelling for daily climate time series—user guide.” *Tech rep. Department of Statistical Science, University College London*.
- CHILÈS, J.P. & DELFINER, P. [1999]. “Geostatistics : modeling spatial uncertainty”. John Wiley & Sons, New York.
- CRESSIE, Noel & WIKLE, Christopher K [2011]. “Statistics for spatio-temporal data”. Wiley, Hoboken, New Jersey.
- DEE, D. P., UPPALA, S. M., SIMMONS, A. J., BERRISFORD, P., POLI, P., KOBAYASHI, S., ANDRAE, U., BALMASEDA, M. A., BALSAMO, G., BAUER, P., BECHTOLD, P., BELJAARS, A. C. M., BERG, L. van de, BIDLOT, J., BORMANN, N., DELSOL, C., DRAGANI, R., FUENTES, M., GEER, A. J., HAIMBERGER, L., HEALY, S. B., HERSBACH, H., HÓLM, E. V., ISAKSEN, I., KÄLLBERG, P., KÖHLER, M., MATRICARDI, M., McNALLY, A. P., MONGE-SANZ, B. M., MORCRETTE, J.-J., PARK, B.-K., PEUBEY, C., ROSNAY, P. de, TAVOLATO, C., THÉPAUT, J.-N. & VITART, F. [2011]. “The ERA-Interim reanalysis : configuration and performance of the data assimilation system”. *Quarterly Journal of the Royal Meteorological Society*. Vol. 137. no. 656, p. 553–597.
- DURBAN, M. & GLASBEY, C.A. [2001]. “Weather modelling using a multivariate latent Gaussian model”. *Agricultural and Forest Meteorology*. Vol. 109. no. 3, p. 187–201.
- FLECHER, C., NAVEAU, P., ALLARD, D. & BRISSON, N. [2010]. “A stochastic daily weather generator for skewed data”. *Water Resources Research*. Vol. 46. no. 7, n/a–n/a.
- GUILLOT, G. [1999]. “Approximation of Sahelian rainfall fields with meta-Gaussian random functions”. *Stochastic Environmental Research and Risk Assessment*. Vol. 13. no. 1-2, p. 100–112.
- GUILLOT, G. & LEBEL, T. [1999]. “Approximation of Sahelian rainfall fields with meta-Gaussian random functions”. *Stochastic Environmental Research and Risk Assessment*. Vol. 13. no. 1-2, p. 113–130.
- HASTIE, T. & TIBSHIRANI, R. [1990]. “Generalized Additive Models”. Monographs on statistics and applied probability. Chapman & Hall.



- HIGDON, Dave, SWALL, J & KERN, J [1999]. "Non-stationary spatial modeling". *Bayesian statistics*. Vol. 6. no. 1, p. 761–768.
- HUGHES, James P. & GUTTORP, Peter [1994]. "Incorporating Spatial Dependence and Atmospheric Data in a Model of Precipitation". *Journal of Applied Meteorology*. Vol. 33. no. 12, p. 1503–1515.
- HUSER, Raphael & GENTON, Marc G [2014]. "Non-Stationary Dependence Structures for Spatial Extremes". *arXiv preprint arXiv :1411.3174*.
- JHA, Sanjeev Kumar, MARIETHOZ, Gregoire, EVANS, Jason, MCCABE, Matthew F. & SHARMA, Ashish [2015]. "A space and time scale-dependent nonlinear geostatistical approach for downscaling daily precipitation and temperature". *Water Resources Research*. Vol. 51. no. 8, p. 6244–6261.
- KATZ, Richard W. & PARLANGE, Marc B. [1995]. "Generalizations of Chain-Dependent Processes : Application to Hourly Precipitation". *Water Resources Research*. Vol. 31. no. 5, p. 1331–1341.
- KELLY, K.S. & KRZYSZTOFOWICZ, R. [1997]. "A bivariate meta-Gaussian density for use in hydrology". *Stochastic Hydrology and Hydraulics*. Vol. 11. no. 1, p. 17–31.
- KILSBY, C.G., JONES, P.D., BURTON, A., FORD, A.C., FOWLER, H.J., HARPHAM, C., JAMES, P., SMITH, A. & WILBY, R.L. [2007]. "A daily weather generator for use in climate change studies". *Environmental Modelling & Software*. Vol. 22. no. 12, p. 1705–1719.
- KLEIBER, William, KATZ, Richard W. & RAJAGOPALAN, Balaji [2012]. "Daily spatiotemporal precipitation simulation using latent and transformed Gaussian processes". *Water Resources Research*. Vol. 48. no. 1. W01523.
- KOLMOGOROV, A.N. [1939]. "Sur l'interpolation et l'extrapolation des suites stationnaires". *Comptes Rendus de l'Académie des Sciences*. Vol. 208, p. 2043–2045.
- KRIGE, DG [1952]. "A statistical analysis of some of the borehole values in the Orange Free State goldfield". *Journal of the Chemical, Metallurgical and Mining Society of South Africa*. Vol. 53, p. 47–70.
- LEBEL, Thierry, BRAUD, Isabelle & CREUTIN, Jean-Dominique [1998]. "A space-time rainfall disaggregation model adapted to Sahelian Mesoscale Convective Complexes". *Water Resources Research*. Vol. 34. no. 7, p. 1711–1726.
- LEBLOIS, Etienne & CREUTIN, Jean-Dominique [2013]. "Space-time simulation of intermittent rainfall with prescribed advection field : Adaptation of the turning band method". *Water Resources Research*. Vol. 49. no. 6, p. 3375–3387.
- MARIETHOZ, Gregoire, RENARD, Philippe & STRAUBHAAR, Julien [2010]. "The Direct Sampling method to perform multiple-point geostatistical simulations". *Water Resources Research*. Vol. 46. no. 11. W11536.
- MATHERON, Georges [1971]. "The theory of regionalized variables and its applications". Vol. 5. Les Cahiers du Centre de Morphologie Mathématique. École National Supérieur des Mines de Paris.
- MEZGHANI, A. & HINGRAY, B. [2009]. "A combined downscaling-disaggregation weather generator for stochastic generation of multisite hourly weather variables over complex terrain : Development and multi-scale validation for the Upper Rhone River basin". *Journal of Hydrology*. Vol. 377. no. 3–4, p. 245–260.
- NAVEAU, P., HUSER, R., RIBERAU, P. & HANNART, A. [2015]. "Modelling jointly low, moderate and heavy intensities without a threshold selection". *Submitted*.
- PACIOREK, Christopher J. & SCHERVISH, Mark J. [2006]. "Spatial modelling using a new class of nonstationary covariance functions". *Environmetrics*. Vol. 17. no. 5, p. 483–506.
- PAVIA, J., LARRAZ, B. & MONTERO, J.M. [2008]. "Election Forecasts Using Spatiotemporal Models". *Journal of the American Statistical Association*. Vol. 103. no. 483, p. 1050–1059.
- RASMUSSEN, Carl Edward & WILLIAMS, Christopher K. I. [2006]. "Gaussian processes for machine learning". The MIT Press.
- RASMUSSEN, P. F. [2013]. "Multisite precipitation generation using a latent autoregressive model". *Water Resources Research*. Vol. 49. no. 4, p. 1845–1857.
- SEMENOV, Mikhail A., BROOKS, Roger J., BARROW, Elaine M. & RICHARDSON, Clarence W. [1998]. "Comparison of the WGEN and LARS-WG stochastic weather generators for diverse climates". *Climate Research*. Vol. 10. no. 2, p. 95–107.
- SHAH, S.M.S., O'CONNELL, P.E. & HOSKING, J.R.M. [1996]. "Modelling the effects of spatial variability in rainfall on catchment response. 1. Formulation and calibration of a stochastic rainfall field model". *Journal of Hydrology*. Vol. 175. no. 1–4, p. 67–88.
- SICHEL, Herbert S [1952]. "New methods in the statistical evaluation of mine sampling data". *Trans Inst Min Metall Lond*. Vol. 61, p. 261–288.
- SIGRIST, Fabio, KÜNSCH, Hans R. & STAHEL, Werner A. [2012]. "A dynamic nonstationary spatio-temporal model for short term prediction of precipitation". *Ann. Appl. Stat.* Vol. 6. no. 4, p. 1452–1477.
- STEHLÍK, Jiří & BÁRDOSSY, András [2002]. "Multivariate stochastic downscaling model for generating daily precipitation series based on atmospheric circulation". *Journal of Hydrology*. Vol. 256. no. 1–2, p. 120–141.

- STEIN, Michael L. [1999]. “Interpolation of Spatial Data : Some Theory for Kriging”. Springer Series in Statistics. Springer-Verlag New York.
- STERN, R. D. & COE, R. [1984]. “A Model Fitting Analysis of Daily Rainfall Data”. *Journal of the Royal Statistical Society : Series A (Statistics in Society)*. Vol. 147. no. 1, p. 1–34.
- VISCHEL, Théo, LEBEL, Thierry, MASSUEL, Sylvain & CAPPELAERE, Bernard [2009]. “Conditional simulation schemes of rain fields and their application to rainfall–runoff modeling studies in the Sahel”. *Journal of Hydrology*. Vol. 375. no. 1–2. Surface processes and water cycle in West Africa, studied from the AMMA-CATCH observing system, p. 273–286.
- VRAC, M. & NAVEAU, P. [2007]. “Stochastic downscaling of precipitation : From dry events to heavy rainfalls”. *Water Resources Research*. Vol. 43. no. 7, n/a–n/a.
- VRAC, M., STEIN, M. L. & HAYHOE, K. [2007d]. “Statistical downscaling of precipitation through nonhomogeneous stochastic weather typing”. *Climate Research*. Vol. 34. no. 3, p. 169–184.
- WHITE, R. H. & TOUMI, R. [2013]. “The limitations of bias correcting regional climate model inputs”. *Geophysical Research Letters*. Vol. 40. no. 12, p. 2907–2912.
- WILKS, D. S. & WILBY, R. L. [1999]. “The weather generation game : a review of stochastic weather models”. *Progress in Physical Geography*. Vol. 23. no. 3, p. 329–357. eprint : <http://ppg.sagepub.com/content/23/3/329.full.pdf+html>.
- WILKS, Daniel S. [2010]. “Use of stochastic weathergenerators for precipitation downscaling”. *Wiley Interdisciplinary Reviews : Climate Change*. Vol. 1. no. 6, p. 898–907.
- WILKS, Daniel S. [2012]. “Stochastic weather generators for climate-change downscaling, part II : multivariable and spatially coherent multisite downscaling”. *Wiley Interdisciplinary Reviews : Climate Change*. Vol. 3. no. 3, p. 267–278.
- WILKS, D.S. [1998]. “Multisite generalization of a daily stochastic precipitation generation model”. *Journal of Hydrology*. Vol. 210. no. 1–4, p. 178–191.
- YANG, C., CHANDLER, R. E., ISHAM, V. S. & WHEATER, H. S. [2005]. “Spatial-temporal rainfall simulation using generalized linear models”. *Water Resources Research*. Vol. 41. no. 11, W11415.
- YEE, Thomas W. [2010]. “The VGAM Package for Categorical Data Analysis”. *Journal of Statistical Software*. Vol. 32. no. 10, p. 1–34.
- ZUCCHINI, Walter & GUTTORP, Peter [1991]. “A Hidden Markov Model for Space-Time Precipitation”. *Water Resources Research*. Vol. 27. no. 8, p. 1917–1923.





# Régimes de temps : vers une nouvelle définition des saisons ?

Où l'on définit les saisons de façon heuristique et les possibles applications de cette étude.

1. Introduction.....	150
2. Publication : Trends and variability of seasonal weather regimes .....	151
Résumé étendu . . . . .	151
1. Introduction . . . . .	154
2. Data and seasons definition . . . . .	155
3. Results: North-Atlantic Z500 seasonal weather regimes . . . . .	157
4. Conditional temperature . . . . .	161
5. Conclusions and perspectives . . . . .	163
3. Un outil d'analyse opérationnel ? .....	164
4. Perspectives.....	166
5. Synthèse des résultats .....	167

# 1. Introduction

Dans ce chapitre, nous sortons du contexte des modèles de réduction d'échelle jusqu'à présent étudiés. Ce travail se fera dans un contexte régional mais ici on ne cherchera pas à établir de lien avec l'échelle locale, l'objet d'étude sera la grande échelle uniquement. Même si le downscaling n'est pas au cœur de ce chapitre, l'étude des régimes de circulation atmosphérique ou régimes de temps (RTs) peut se révéler intéressante dans ce contexte. En effet, les modèles de réduction d'échelle ayant pour but de lier la grande échelle à l'échelle locale, il est bon d'avoir une bonne connaissance des changements dans les structures de circulation atmosphérique afin de les répercuter correctement à l'échelle locale. Il existe dans la littérature plusieurs études de downscaling utilisant les RTs pour conditionner les modèles de downscaling [ZUCCHINI & GUTTORP, 1991 ; HUGHES & GUTTORP, 1994 ; SCHNUR & LETTENMAIER, 1998 ; BELLONE et al., 2000 ; VRAC et al., 2007d ; AILLIOT et al., 2009 ; WILKS, 2012 ; HABERLANDT & RADTKE, 2014].

Nous nous intéressons à la saisonnalité du climat et le but ici est de la caractériser à partir de la circulation atmosphérique et d'étudier la variabilité et les tendances des structures atmosphériques saisonnières. Ce travail concerne l'*Objectif n°3* de ce manuscrit : la redéfinition des saisons à partir d'une modélisation des régimes de circulation atmosphérique.

Les saisons et la saisonnalité sont les principales caractéristiques du climat extra-tropical qui affecte l'intensité des événements météorologiques et donc les écosystèmes et la société. Les quatre saisons se définissent usuellement selon un critère astronomique qui correspond à une variation périodique de la quantité d'énergie solaire reçue par l'atmosphère. On détermine ainsi quatre dates : deux équinoxes et deux solstices qui déterminent respectivement le début du printemps et de l'automne et le début de l'été et de l'hiver. Du point de vue météorologique, cela ne correspond pas nécessairement aux variations des variables de surface : on observe que d'une année sur l'autre, le moment de la transition d'une saison à une autre fluctue [DONAT et al., 2010]. Par exemple, le mois d'avril 2011 a été exceptionnellement chaud : avec une température moyennée sur la France supérieure de 4,0 °C à la normale, il se positionne au second rang des mois d'avril les plus chauds depuis 1900, derrière 2007 (+4,3 °C) et loin devant 1945 (+2.8 °C) avec des températures quasi-estivales. Au printemps 2013, l'Europe du Nord et les États-Unis connaissent une vague de froid digne d'un hiver rigoureux, avec des records de froids dans l'est de la France et des chutes de neige sur l'ensemble de la France en mars 2013.

La problématique ici est d'appréhender et de caractériser ce genre de fluctuations. Ce chapitre donne une définition de la saisonnalité du climat à partir d'une analyse statistique de la circulation atmosphérique sur l'Atlantique Nord. Notre approche est basée sur l'analyse des RTs. Le concept de régime de temps a été introduit par REINHOLD & PIERREHUMBERT [1982] afin de caractériser les structures atmosphériques récurrentes et persistentes.

Il existe plusieurs méthodes statistiques pour déterminer les RTs [par exemple, VRAC et al., 2007b ; VRAC & YIOU, 2010 ainsi que les références qui y sont citées]. Les RTs sont usuellement obtenus à partir d'une méthode de classification non-supervisée (également appelée méthode de clustering), c'est-à-dire que ces méthodes ne présupposent pas de la nature des différentes classes, leur nature est définie *a posteriori*. Dans notre cas, notre méthode permet en plus de cela de définir le nombre de

classes de façon objective en se basant sur un critère d'optimalité que nous développerons dans la suite.

Usuellement, les RTs sont étudiés pour une saison donnée [l'hiver extra-tropical en général, par exemple, MICHELANGELI et al., 1995 ]. Or, le but ici est d'étudier la saisonnalité des structures atmosphériques qui influencent la perception du temps qu'il fait et qui ne se cantonnent pas uniquement à la température ou à une quantité d'énergie reçue. Pour ce faire, nous allons prendre en compte les données sur l'ensemble de l'année et nous évaluerons d'une part les tendances et la variabilité de ces RTs ainsi que l'évolution de la température de surface conditionnellement à ces RTs. Ceci sera développé à la SECTION 2 sous la forme d'une publication qui sera précédée d'un résumé en français. On verra ensuite à la SECTION 3, une application potentielle ainsi que diverses pistes pour exploiter les résultats de cette étude dans un contexte opérationnel.

## 2. Publication : Trends and variability of seasonal weather regimes

### Résumé étendu

L'objectif de cet article est d'étudier les tendances et la variabilité des RTs saisonniers. Le résumé suit la progression de l'article en se focalisant sur trois points : les données de circulation atmosphérique utilisées dans la définition des saisons, qui sont décrites dans la section 2, les différents résultats de l'évaluation des tendances et de la variabilité des RTs ainsi que l'évolution temporelle de la température conditionnelle (voir section 3 et 4 de l'article) et les principales perspectives (section 5 de l'article).

**N.B.** : l'introduction de l'article n'est pas résumée car elle concerne des points déjà évoqués en détail dans ce manuscrit (l'introduction de l'article correspond à l'introduction de ce chapitre) notamment au CHAPITRE I, SECTION 2 de ce manuscrit. Un lecteur pressé pourra donc aller directement à la section 2 de l'article.

---

### *Données et définition statistique des saisons*<sup>1</sup>

Les RTs sont définis à partir des champs de hauteur du géopotential à 500hPa (Z500) issus des réanalyses du National Center for Environmental Prediction/National Center for Atmospheric Research [NCEP/NCAR, KALNAY et al., 1996 ] à la résolution  $2.5^\circ \times 2.5^\circ$  sur la période du 1<sup>er</sup> janvier 1948 au 31 décembre 2011. La température de surface est aussi utilisée pour l'analyse conditionnelle. Les deux variables sont considérées au pas de temps journalier. La région d'intérêt est l'Atlantique Nord telle que définie dans YIOU & NOGAJ [2004] par exemple et s'étend sur la zone géographique  $[-77.5^\circ\text{E} ; 37.5^\circ\text{E}] \times [22.5^\circ\text{N} ; 70.0^\circ\text{N}]$ .

Dans la plupart des études portant sur les régimes de temps, l'analyse porte sur les anomalies de circulation par rapport au cycle saisonnier et permet de définir des régimes de variabilité pour

---

1. section 2 de l'article

des saisons de trois mois fixes. Or, ce qui nous intéresse ici est précisément de caractériser cette saisonnalité, ce qui n'est pas possible lorsque les particularités saisonnières des données sont retirées comme c'est le cas pour les anomalies par rapport au cycle saisonnier. Nous procédons directement à partir des données brutes, ce qui est l'une des originalités de cette étude. Seule la première composante principale de Z500 issue d'une ACP sera utilisée pour définir les RTs (pour plus de détails sur la procédure de traitement, se référer à la section 2.1 de l'article).

Notre approche consiste à réaliser une classification de l'ensemble des jours sur la période 1948-2011 pour définir les RTs, étudier leur spécificité temporelle d'occurrences durant l'année et les associer à une saison donnée pour étudier leur évolution temporelle. L'approche de clustering de VRAC et al. [2007b] est adoptée ici. Elle se base sur l'algorithme espérance-maximisation (EM) introduite par DEMPSTER et al. [1977]. Cet algorithme ajuste une densité de probabilité (pdf) multivariée (dans notre cas, elle sera univariée puisque qu'on n'utilise que la première PC) à nos données comme un mélange pondéré de  $K$  pdf gaussiennes [PEARSON, 1894],  $K$  étant le nombre de RTs déterminé par l'algorithme de façon automatique (se référer à la section 2.2 de l'article pour plus de détails). Dans notre cas, un nombre optimal de  $K = 4$  régimes est obtenu.

### *Principaux résultats*<sup>1</sup>

Nous arrivons à associer les quatre régimes à quatre périodes de l'année (c.f. FIGURE 3 de l'article) :

- le régime 1 (R1), représenté en noir, correspond globalement à l'hiver (de Novembre à Avril),
- les régimes 2 and 3 (R2 et R3), représentés respectivement en rouge et en vert, sont prédominants au printemps et en automne,
- le régime 4 (R4), représenté en bleu, correspond à l'été (de juin à septembre).

Le régime R2 (en rouge) représente un régime de transition depuis et vers les conditions hivernales (R1, en noir) et R3 (en vert) fait la transition depuis et vers les conditions estivales (R4, en bleu).

### Evolution temporelle des saisons : tendance and variabilité

Grâce à cette définition nous pouvons étudier en particulier les conditions de circulation atmosphérique de types hivernales et estivales. Un résultat important est que la fréquence de l'occurrence des jours ayant des conditions de circulation estivales pour les mois de mai à octobre augmente alors que celle des conditions hivernales diminue pour les mois de novembre à avril sur la période 1948-2011. On a également mis en évidence que les étés sont plus longs et les hivers plus courts dans les années 2000 que dans les années 1950.

### Evolution temporelle des températures conditionnellement aux RTs

On s'intéresse aux températures composites, c'est à dire aux structures de température conditionnellement aux RTs. On constate que les tendances de températures dépendent des RTs avec des évolutions positives ou négatives en fonction de la sous-région considérée. Cela conduit à la nécessité de réduire la région d'étude afin de mieux appréhender l'évolution des températures dans un contexte de changement climatique, notamment par l'utilisation de modèles de downscaling.

---

1. sections 3 et 4 de l'article

### *Quelques perspectives*<sup>1</sup>

Cette étude amène un certain nombre de perspectives. Par exemple :

- une suite logique de ce travail est l'application de cette définition des saisons aux GCMs ou RCMs et l'évaluation de la capacité des modèles climatiques à reproduire ces tendances tant en termes de saisonnalité que de température, pour la même période de temps,
- on peut également imaginer un système de prévision saisonnière puisque le modèle proposé permet d'adapter la définition des saisons aux conditions atmosphériques. À l'aide de champs de variables atmosphériques issus de prévisions saisonnières, il est possible de projeter (*cf.* ÉQUATION 3 de l'article) une séquence de jours sur les régimes obtenus pour prévoir la précocité ou le retard éventuel du début de l'été, ce qui est intéressant par exemple pour la prévision de vagues de chaleur ou de sécheresses provoquées par des conditions précoces de la saison chaude [VAUTARD et al., 2007].
- En utilisant la même procédure, on peut envisager des projections de l'évolution future de la saisonnalité à plus long terme à l'aide des projections climatiques issues des GCMs ou des RCMs.

Nous verrons à la SECTION 3 un exemple d'application de ces travaux et nous aborderons à la SECTION 4 quelques perspectives supplémentaires.

---

1. section 5 de l'article



## Trends and variability of seasonal weather regimes

Mathieu Vrac,\* Pradeebane Vaittinada Ayar and Pascal Yiou

Laboratoire des Sciences du Climat et de l'Environnement (LSCE-IPSL), CNRS/CEA/UVSQ, Centre d'Etudes de Saclay, Orme des Merisiers 91191, Gif-sur-Yvette, France

**ABSTRACT:** Seasons and seasonality are the main properties of extra-tropical climate that affect ecosystems and society. For example, agriculture, tourism, energy consumption or ecosystem phenology are primarily dependent on seasonality and on the magnitude of the meteorological events associated within each season. Changes in the seasonality of variables like surface temperature during the last decades have been widely investigated but seasonal changes of the weather have received less quantification. This paper redefines the concept of seasonality based on the extra-tropical atmospheric circulation, and on the notion that it can drive the evolution of temperature. We find that summer-like atmospheric conditions have appeared earlier and ended later since 1948. Conversely, the period with winter patterns has reduced over that period. The temperatures associated with weather patterns allow to identify the sources of temperature trends.

**KEY WORDS** clustering; Expectation-Maximization algorithm; mixture model

Received 20 July 2012; Revised 5 December 2012; Accepted 18 February 2013

### 1. Introduction

The four seasons are classically defined according to astronomical criteria: equinoxes define beginning of Spring and Autumn, solstices define beginning of Summer and Winter. Those dates correspond to epochs of different quantities of solar energy received at the top of the atmosphere. Therefore, they correspond to first-order variations of temperature in the extra-tropics. This climatological definition gives the dates of beginning and end of seasons, which are easily predictable from astronomical calculations. Yet, from a meteorological point of view, the fluctuations of surface variables almost never fit the periodic variations of the insolation at the top of the atmosphere. Hence, the observed transitions of surface variables like temperature, pressure or precipitation from one season to another fluctuate from year to year. For example, the extra-tropical storm activity is maximal during the December–February period in the northern hemisphere. This feature is connected to increased pressure gradients around the North Atlantic. Those gradients do have a strong seasonal component, but shifts in the timing of the maximum activity could modulate the impacts of storms that strike Europe (e.g. Donat *et al.*, 2010) during the cold season.

There have been many studies on seasonality and its changes for past or future climate projections (Trenberth *et al.*, 2007). For example, a rotated principal components

analysis (RPCA) to monthly fields of 700mb geopotential heights (Z700) over Northern hemisphere was performed to understand the main modes of variability and their seasonality during the 1950–1984 time period (Barnston and Livezey, 1987). More recently, Vrac *et al.* (2007) tested two clustering methods to define North American seasonal weather regimes based on Z500, Z700, Z850 or sea level pressure (SLP) reanalysis data and evaluated the capability of two Global Climate Models (GCMs) to reproduce their correct patterns and seasonal frequencies. In terms of temporal changes of seasonality, Jacobeit *et al.* (2002) used a T-mode PCA applied to monthly SLP over North Atlantic European area from 1659 to 1999 to study the temporal evolution of the January and July structures and their frequencies. To study sea level variability in the North Atlantic, Barbosa *et al.* (2005) decomposed sea level anomalies time series into non-stationary seasonal and trend components based on a multi-resolution analysis, before applying separate PCAs on the two components. Over Europe, Zveryaev (2006) studied the seasonal modes of variability of the monthly precipitation itself using EOF during the 20th century and found links with atmospheric circulation such as the North Atlantic Oscillation (NAO) pattern for winter, spring and summer precipitation, and the Scandinavian teleconnection pattern for fall precipitation. Over the United States, Wang *et al.* (2009) showed that, from 1950 to 2000, temperature and precipitation present trends different from the seasons: a warming trend during winter, spring and early summer and a modest countrywide cooling trend in late summer and fall, while precipitation only shows positive trends in all seasons, with the largest one in fall. Moron *et al.* (2010) considered the

\* Correspondence to: M. Vrac, Laboratoire des Sciences du Climat et de l'Environnement (LSCE-IPSL), CNRS/CEA/UVSQ, Centre d'Etudes de Saclay, Orme des Merisiers 91191, Gif-sur-Yvette, France. E-mail: mathieu.vrac@lsce.ipsl.fr

the seasonal cycle as well as inter-annual variability using weather regimes at regional scale to study the austral summer monsoon onset and post-onset rainfall and their associated low-level winds during the August–February season over Indonesia. Most of those mentioned studies revealed some evidences of seasonality in the character of the long-term changes of temperature or precipitation, which may have consequences on seasonal flood trends, as demonstrated, e.g. by Petrow et al. [2009] for Germany.

This paper provides a heuristic definition of weather seasonality, from a statistical analysis of atmospheric circulation variability over the North Atlantic, and explores trends of observed seasonal atmospheric patterns. Our approach is based on the analysis of weather regimes or patterns obtained from statistical clustering of geopotential height data. Weather regimes can be defined as recurring atmospheric patterns [e.g. Vrac & Yiou, 2010]. Most studies have investigated weather regimes within a given season [generally the winter in the northern hemisphere extra tropics, e.g. see Michelangeli et al., 1995; Yiou & Nogaj, 2004 and references therein]. Hence, by considering year round data, this paper focuses on the seasonality of atmospheric patterns, which influences the weather perception (‘fair’ vs. ‘bad’) and the season-dependant activities. The rationale is that the seasons are also perceived through the weather variability, rather than just temperature or an average energy balance.

Moreover, we will determine how the signature of seasonal weather regimes on surface temperature evolves through time. This will provide insight on the mechanisms leading to changes in temperature seasonality.

SECTION 2.1 will detail the data and data preparation for the paper. SECTION 2.2 will explain the methodology. Results on the seasonality and trends of North Atlantic weather regimes will be given in SECTION 3. We present the dependence of surface temperature variations to weather patterns in SECTION 4. Conclusions are provided in SECTION 5.

## 2. Data and seasons definition

### 2.1. Data

Our definition of seasonal weather regimes is based on geopotential heights at 500 hPa (Z500) fields from National Centers for Environmental Prediction/National Center for Atmospheric Research (NCEP/NCAR) daily reanalysis data [Kalnay et al., 1996] with a  $2.5^\circ$  spatial resolution, from 1 January 1948 to 31 December 2011. The Z500 data is a common variable in many weather regimes studies [e.g., Michelangeli et al., 1995; Yiou & Nogaj, 2004; Cassou, 2008]. It was chosen here because it integrates atmospheric fluctuations up to the mid troposphere and is less noisy than sea-level or surface pressure. We also used the surface temperature of the NCEP database in a second conditional analysis. Both fields are taken at the daily time scale. The region of interest covers the North-Atlantic region, as defined for example in Yiou & Nogaj [2004] or Vrac & Yiou [2010], and corresponds to  $940$  grid-cells over the geographical zone  $[-77.5^\circ E; 37.5^\circ E] \times [22.5^\circ N; 70^\circ N]$ .

In many weather regimes studies [e.g., Yiou & Nogaj, 2004; Rust et al., 2010 and references therein], the data are first deseasonalized in order to work on anomalies instead of the ‘raw’ data, or separated into predefined seasons (covering fixed calendar months) to avoid influencing the analyses by season-specific modelling. However, the main goal of this paper is precisely to characterize this seasonality, which is not possible if data are pre-processed by removing seasonal specificities. Thus, extracting the annual cycle first would mean that we would analyse seasonality of the anomalies, which is not the purpose of this study. Hence, we do not remove any seasonal cycle or any long-term mean from the dataset used to define the weather regimes.

Before applying a clustering method to define seasonal regimes, a PCA is applied to the data matrix in order to reduce the dimension of the data. When applying the PCA, the Z500 data are weighted by the square root of the cosine of the latitude to give equivalent weights to all grid-cells [e.g., as in Michelangeli et al., 1995; Yiou & Nogaj, 2004; Cassou, 2008]. The first principal component (PC) contains more than 52% of the

total variance of the initial Z500 data fields and we need to retain 10 PCs to keep more than 90% of the total variance. However, in this study, as we seek to characterize seasonality, we are mostly interested in capturing the signal related to annual cycle. Therefore, a Fourier spectral analysis has been performed on the PCs. Then, the contribution of each PC  $i$  to the annual frequency  $\omega_0 = 1/365$  cycles per day ( $\Gamma_{ann}(PC_i)$ ) has been evaluated through:

$$\Gamma_{ann}(PC_i) = \frac{S_{PC_i}^2(\omega = \omega_0)}{\sum_{k=1}^{940} S_{PC_k}^2(\omega = \omega_0)} \times 100, \quad (1)$$

where  $S_{PC_k}^2(\omega = \omega_0)$  is the spectrum power of the  $k^{th}$  PC calculated at annual frequency. The result is that  $\Gamma_{ann}(PC_1)$  exceeds 99.9%, indicating that the first PC alone already captures more than 99.9% of the signal related to the annual cycle.

Hence, in the following, although  $PC_1$  contains ‘only’ 52% of the total variance, only the first PC is kept because the others are negligible to characterize the annual cycle. Tests have been performed on different numbers of PCs (until 10 PCs): they all provided equivalent results (not shown). Therefore, only results based on the first PC are shown in this article.

## 2.2. Seasons seen as “clusters”: the EM approach

Our approach consists in clustering all the days in the time period 1948-2011 to define weather regimes associated with or characterizing specific seasons, and to study their cycle of occurrences, as well as their potential temporal evolutions. The clustering approach of Vrac et al. [2007b] is used to define the seasonal weather regimes. It is based on the “Expectation-Maximization” (EM) clustering method [Dempster et al., 1977; Fraley & Raftery, 2002; McLachlan & Peel, 2000]. This algorithm estimates a multi-variate probability density function (pdf)  $f$  of our data (i.e., the daily vectors of PCs) as a weighted sum (or mixture) of  $K$  Gaussian pdf’s  $f_k$  ( $k = 1, \dots, K$ ) [Pearson, 1894]:

$$f(\mathbf{x}) = \sum_{k=1}^K \pi_k f_k(\mathbf{x}; \boldsymbol{\alpha}_k), \quad (2)$$

where  $\boldsymbol{\alpha}_k$  is the vector of parameters of component  $k$ , and  $\pi_k$ ’s are called the “mixture ratios” and correspond to the prior probability of belonging to component  $k$ . One cluster  $C_k$  of days is then defined per Gaussian pdf  $f_k$  by applying the principle of *posterior* maximum:

$$C_k = \{\mathbf{x}; \pi_k f_k(\mathbf{x}, \boldsymbol{\alpha}_k) \geq \pi_j f_j(\mathbf{x}, \boldsymbol{\alpha}_j), \forall j = 1, \dots, K\}. \quad (3)$$

In other words, each  $\mathbf{x}$  (i.e., each day characterized by its vector  $\mathbf{x}$  of PCs) is attributed to the cluster  $C_k$  for which the pdf  $f_k$  maximizes the posterior probability that  $\mathbf{x}$  belongs to this cluster. In the present application, the obtained clusters are the searched seasonal weather regimes.

The choice of the number  $K$  of clusters (here seasonal weather regimes) is still an open question and different possibilities are offered depending on the clustering method [Vrac et al., 2007b]. A very common approach in mixture modelling consists of running EM several times for various numbers  $K$  of regimes and using the number that maximizes a given criterion [McLachlan & Peel, 2000]. Here, the chosen criterion to be optimized is the Bayesian Information Criterion [BIC, Schwarz, 1978 ]:

$$BIC(K) = -2 \log(L) + p \log(n), \quad (4)$$

where  $L$  is the likelihood of the parametrized mixture model with  $K$  clusters,  $n$  is the sample size (i.e., total number of days from January, 1, 1948 to December, 31, 2011, that is 23.376 days), and  $p$  the number of parameters to be estimated. Minimizing the BIC offers a consistent and transparent way of determining the number  $K$  of components corresponding to a compromise between a good likelihood and a reasonable number of parameters.

Once the year-round weather regimes are determined, we compute the frequency of each regime within all 12 months separately. The monthly frequency of a given weather regime for a given month is the ratio of the number of daily occurrences of this regime for this month, over the number of days in the month. All atmospheric fields yield a strong seasonal periodicity. Hence, we also expect the frequency of each regime to yield a seasonal periodicity. This justifies the ‘seasonal’ weather

regime terminology. The periodicity and phase of the weather regimes allow us to redefine seasons with respect to atmospheric patterns. We determine first and last dates of occurrences of seasonal weather regimes and look at their evolution in time. This allows us to define trends in seasonal weather regimes.

This will be illustrated in Section 3.2.

### 3. Results: North-Atlantic Z500 seasonal weather regimes

#### 3.1. Seasonal structures and cycles

The EM algorithm has been run for  $K$  regimes ranging from 2 to 15 based on data over the 1948–2011 time period. The BIC optimization provides  $K = 4$  as the best number of weather regimes. However, to test the robustness of the number of regimes selected by the BIC, a bootstrap-like process has been applied. The EM algorithm has been applied 100 times to a sub-sample of the total set containing 75% of the data randomly selected and the BIC is computed for each  $K$  from 2 to 15 for each sub-sample. The envelope of the BIC values, presented in FIGURE 1, clearly confirms the choice of  $K = 4$  regimes.

The structures of the associated mean seasonal Z500 weather regimes are presented by the isolines in FIGURE 2.

Colours indicate associated anomalies of Z500, i.e. differences of the Z500 ‘raw’ data with respect to the Z500 mean daily annual cycle defined as the climatological daily means smoothed by a smoothing spline function. Another characterization of this annual cycle (through *empirical* mean daily annual cycle) has been tested and provided equivalent results (not shown). Hence, for a smooth representation of the cycle, the spline-based approach has been preferred. Note that the anomalies are computed for visualization only. They do not enter into account in any of the clustering or trends analyses. As it was found in a COST Action on ‘Harmonisation and Applications of Weather Types Classifications for European Regions’ (<http://cost733.met.no>) that different clustering techniques may show very different properties [Philipp et al., 2010], the  $K$ -means clustering algorithm has also been applied for comparison. Similar results were obtained for the seasonal regimes (as well as for following figures and results) when applying  $K$ -means (not shown), indicating a good robustness of the results




Figure 1: BIC values obtained by applying the EM algorithm 100 times to sub-samples of the total set containing 75% of the data randomly selected. The BIC is computed for each  $K$  from 2 to 15 for each sub-sample. This clearly confirms the choice of  $K = 4$  regimes.

to the clustering methodology. However, the advantage of the EM approach is that it is less restrictive than  $K$ -means and allows to employ the BIC to select the optimal number of clusters [e.g. Rust et al., 2010]. Regimes 3 and 4 do not show very pronounced anomaly structures since mean anomalies per regime stay around 0 (yellow). However, Regimes 1 and 2 yield more pronounced patterns meaning that, on average, the days attributed to those regimes have Z500 fields different from the seasonal cycle values in those regions. Regimes 1 and 2 are respectively associated with the positive and negative phases of the North Atlantic Oscillation (NAO). Regime 1 yields a South to North Z500 anomaly gradient, with a zonal flow corresponding to the positive phase of the NAO.

Regime 2 shows an opposite Z500 anomaly structure, with a negative anomaly around  $40^\circ$  N and a positive anomaly around  $50^\circ$  N. This corresponds to the negative phase of the NAO.

The mean monthly frequencies illustrate the seasonality of those weather regimes (FIGURE 3).

Regime 1 (R1, black line) mostly corresponds to Winter (November–April) conditions, Regime 4 (R4, blue line) to Summer (June–September) and Regimes 2 and 3 (R2 and R3, red and green lines respectively) mostly dominate the intermediate seasons (Spring and Fall).

Regime 2 (red) is clearly more associated with transitions from or towards winter conditions (R1, black), while Regime 3 (green) allows transitions from or towards summer conditions (R4, blue).

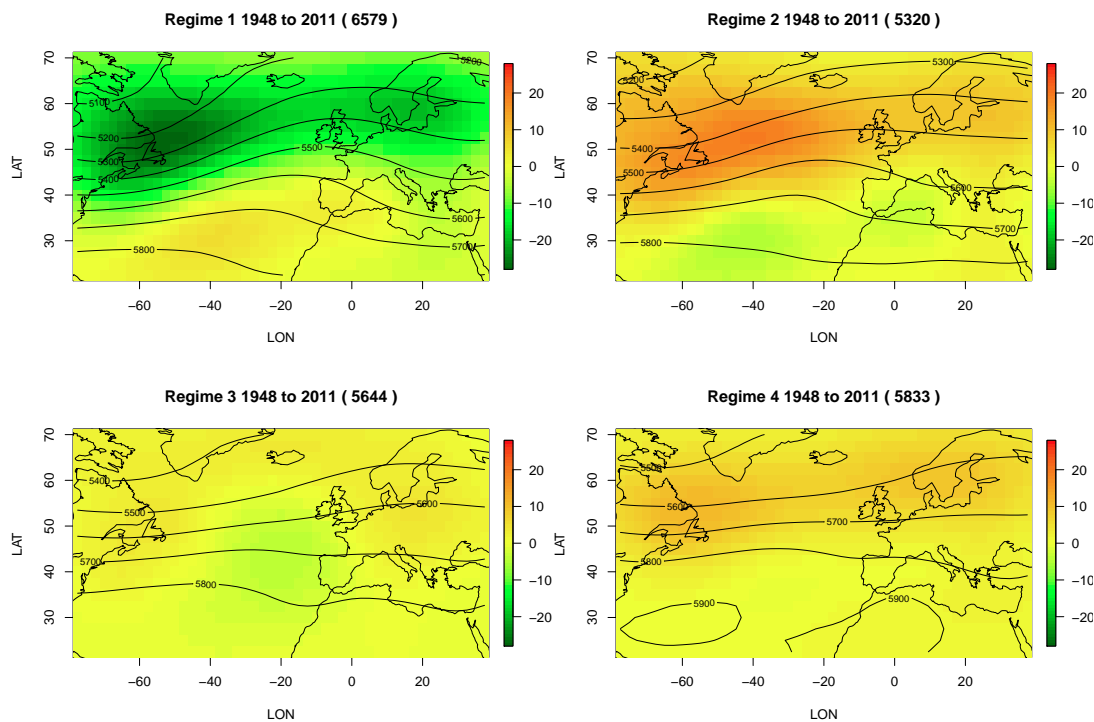


Figure 2: Maps of the four seasonal weather regimes defined by EM. Colours correspond to mean Z500 anomalies per regime with respect to seasonal cycle; black lines represent the mean geopotential heights in meters. In each panel, the number indicates how many days belong to the regime.

### 3.2. Temporal evolutions of the seasons: trends and variability

Although the four seasonal regimes have been defined for the whole period 1948–2011 – ensuring that they are consistent all along this period –

their frequencies can vary and evolve from year to year. To test this point, the evolution of the regime frequencies for each month from 1948 to 2011 has been computed. FIGURE 4 shows two examples for March (FIGURE 4(a)) and September (FIGURE 4(b)).




Figure 3: Monthly frequencies of the four seasonal weather regimes defined by EM.




Figure 4: Temporal evolution of the mean regime frequencies for two example months – (a) March and (b) September – over the period from 1948 to 2011.

In those 2 months, some frequencies may yield a linear trend. For March (FIGURE 4(a)), Regime 2 (early spring or late fall, red line) shows an increase of its frequencies conversely to R1 (winter, black line), whose frequencies decrease.

Also, for September (FIGURE 4(b)), Regime 3 (late spring or early fall, green line) shows a decrease (at least from the mid-1970s) that is compensated by the increase of R4's frequencies (summer, blue line). To quantify and summarize the significance of those trends, Table 1 presents the slope of the linear trends considered as significant at 95% ( $\alpha = 0.05$ ) based on a t-test trying to reject the null hypothesis that 'the slope is equal to 0'.

The frequency of the winter regime (R1) decreases for all months between December and April but January, corresponding globally to fewer winter conditions for the whole winter period. Most of those negative trends are compensated by the increasing frequencies of the 'transition' regimes (R2 or R3). Summer regime (R4) shows increasing frequencies from June to October (except in July where R4's frequencies are already very close to one), mostly counterbalanced by decreasing R3's frequencies. Those increasing trends indicate that summer conditions are more frequent at the end of the 2000s than in the previous decades.

In August, although small because its frequencies are already close to one in FIGURE 3, the trend of the R4 frequencies is significantly positive. Those results are in agreement with Jacobeit et al. [2002] who showed that the long-term evolution in Summer of the west-erly mode indicates a general increase of anti-cyclonic conditions strengthening during the last decades. Slopes for June, September and October suggest earlier summer conditions and/or faster transition from spring to summer (June), and longer summer conditions and/or faster transition from summer to autumn (September, October).

However, an increasing or decreasing trend in frequency of a regime for a given month characterizing the beginning or end of a 'classical' season – for example,



Table 1: Values of the slopes (significant at 95%, i.e.,  $\alpha = 0.05$ ) of the monthly frequencies' trends of each seasonal weather regime (WR) calculated over 1948–2011.

	Jan	Feb	Mar	Apr	May	Jun	Jul	Aug	Sept	Oct	Nov	Dec
WR 1		$-1.5 \times 10^{-3}$	$-3.6 \times 10^{-3}$	$-2 \times 10^{-3}$								$-4 \times 10^{-3}$
WR 2		$1.5 \times 10^{-3}$	$3.6 \times 10^{-3}$		$-2.5 \times 10^{-3}$							$4 \times 10^{-3}$
WR 3				$2 \times 10^{-3}$	$2.5 \times 10^{-3}$	$-4 \times 10^{-3}$		$6 \times 10^{-4}$	$-4 \times 10^{-3}$			
WR 4						$4 \times 10^{-3}$		$6 \times 10^{-4}$	$4 \times 10^{-3}$	$7 \times 10^{-4}$		

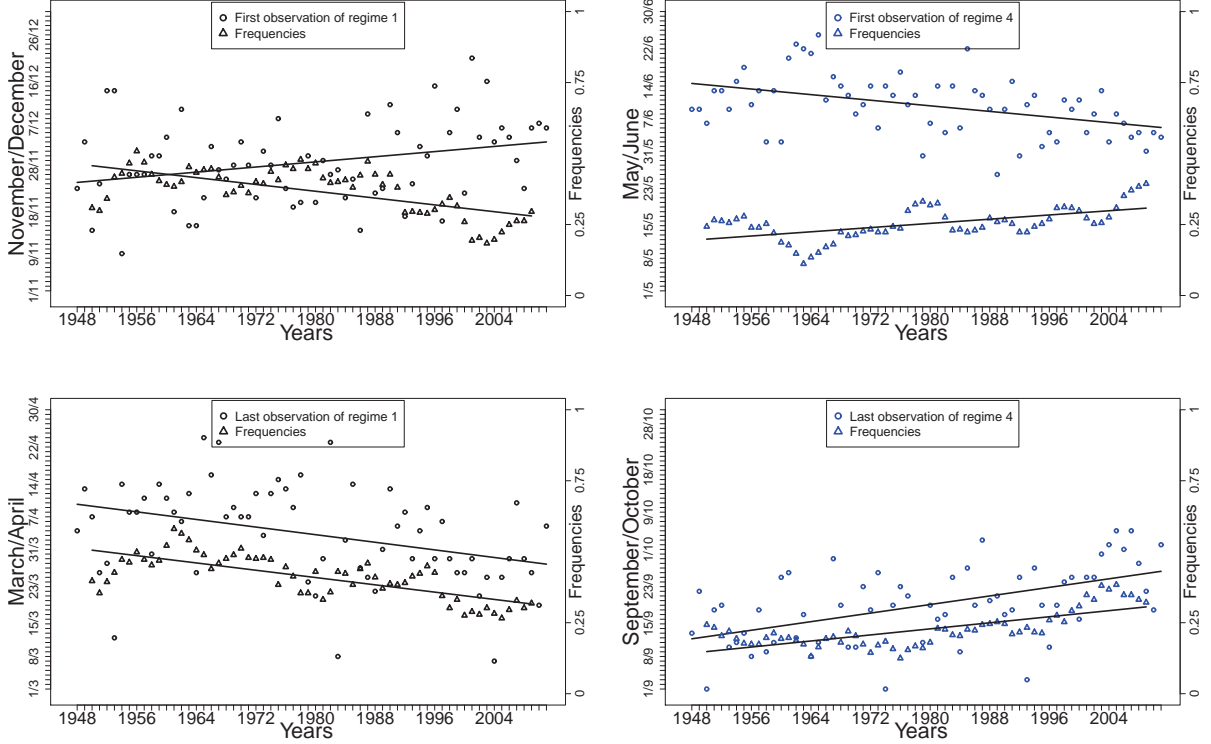


Figure 5: Year-to-year evolution of the first (top row, a and b) and last (bottom row, c and d) dates of observation (circles) for the Winter regime (R1, left panels, a and c) and the Summer regime (R4, right panels, b and d). The evolution of the frequencies of these regimes for the 2 month-periods of beginning or end of the seasons is indicated with triangles.

increasing of R4 (summer) in June – does not imply that the season (summer) associated to the regime (R4) starts earlier or later. Frequencies can increase or decrease even though the first or last dates of occurrence do not change. Hence, the first and last dates of occurrences of the winter (R1) and summer (R4) regimes were used to quantify the phase changes of seasonality of those two weather regimes. FIGURE 5 shows the trends of the dates for the period 1948–2011. The evolution of the frequencies of these regimes for the 2-month-periods of beginning or end of the seasons is also indicated.

The date evolutions are coherent with the frequencies, and show how those regimes shift in

time. All those (frequency and first or last date) linear trends are significant at 95% (i.e.  $p$ -values  $< 0.05$ ). Winter weather conditions tend to occur later (FIGURE 5(a)), and end sooner (FIGURE 5(c)) during the year. Hence, globally, winters have shortened since the 1950s. Conversely, the summer weather regime tends to occur sooner (FIGURE 5(b)) and end later (FIGURE 5(d)) in the year, contributing to a longer summer season since the 1950s. Most of those conclusions hold for the first and last dates of occurrence of the regimes for spells of  $n = 3, 5$  or  $7$  consecutive days: except the trend of the last date of the summer regime (R4) whose significance quickly decreases, all trends are significant at more than 85% (i.e.  $p$ -values  $< 0.15$ ) even for the 7-day spells occurrences.

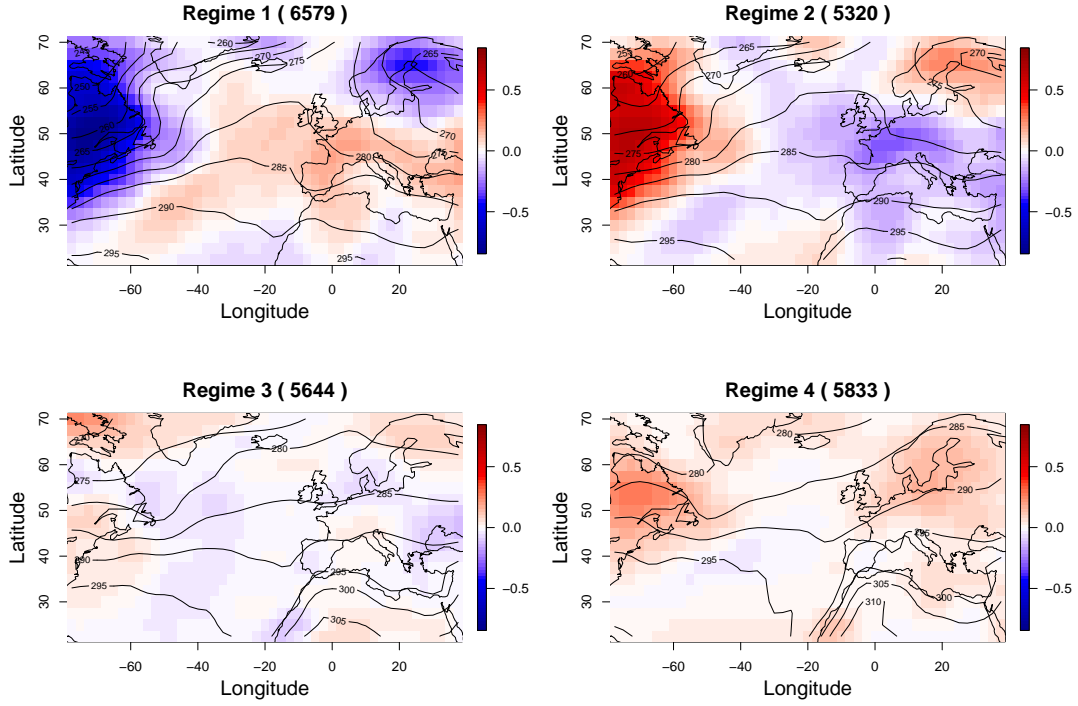


Figure 6: Maps of the conditional temperature for each of the four seasonal weather regimes. Colors correspond to mean temperature anomalies per regime with respect to seasonal cycle; black contours represent the mean temperature (in Kelvin).

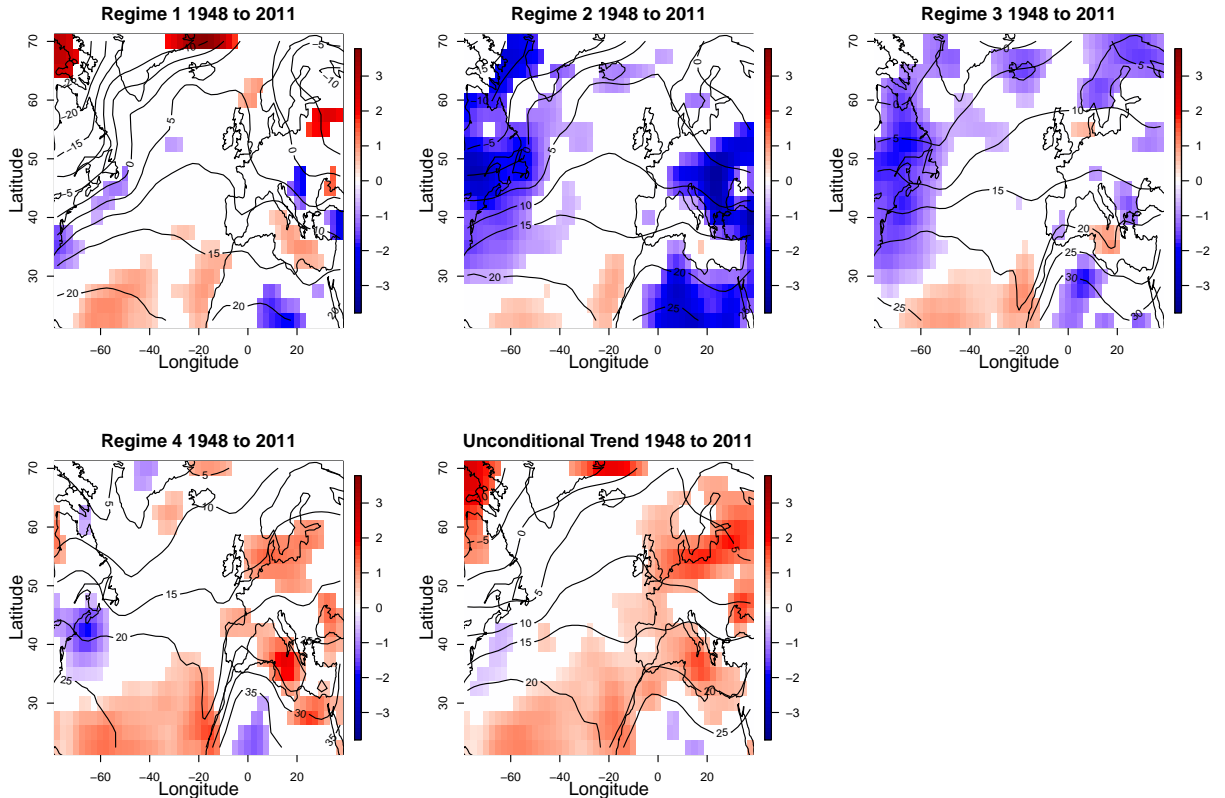


Figure 7: Trends of temperature (in Kelvin) per seasonal regime as well as disregarding the conditioning by seasonal regimes (bottom right panels) over 1948-2011.

## 4. Conditional temperature

Local surface temperature is mostly controlled by incoming radiation and atmospheric circulation

variability that drives the advection of heat. In the North Atlantic region, the role of atmospheric circulation is prominent in the winter, but does play a role in developing extreme events in the summer



[Cassou et al., 2005; Vautard et al., 2007]. The effect of the seasonal regimes on surface temperature can be obtained by decomposing the surface temperature into components from each seasonal regime (i.e. temperature patterns conditional to weather regimes) as presented in FIGURE 6, and residual noise [Corti et al., 1999; Cassou et al., 2005].

Similarly to FIGURE 2, those maps do not show pronounced patterns of anomalies for Regimes 3 and 4, while R1 and R2 appear with the most contrasted structure.

One other way to discriminate the temperature influence of those regimes is to examine the conditional temporal evolution of temperature given a

seasonal weather regime. Hence, for each grid-cell in each regime, a regression has been computed to describe the linear evolution of temperature in function of time. FIGURE 7 displays for each regime the resulting slopes – over the 1948–2011 period – which are significantly different (at 95%) from 0 based on a  $t$ -test.

All four regimes show significant temperature trends. While R2 and R3 mostly display strong negative trends (despite patches of positive trends), Regimes 1 and 4 are more contrasted with both positive and negative trends, depending on the sub-region. For the four regimes, the south of this North-Atlantic region shows more or less pronounced positive evolutions of temperature, whatever the regime.

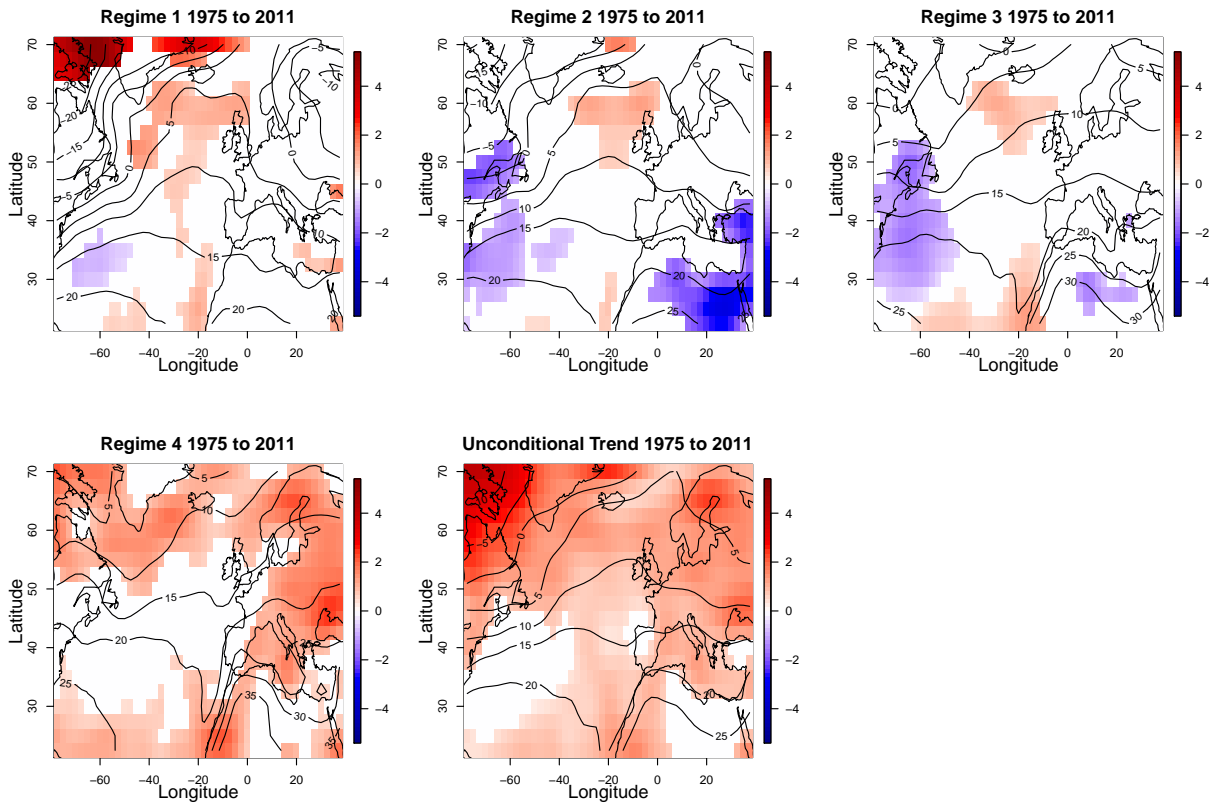


Figure 8: Trends of temperature (in Kelvin) per seasonal regime as well as disregarding the conditioning by seasonal regimes (bottom right panels) but over 1975–2011.

However, like for any trend analysis, the results may depend on the time period on which the regression is calculated. To test this point, the same analysis has been performed from the 1975–2011 period. Indeed, when looking at the temporal trends of the frequencies of the regimes, the linearity of the evolutions appears more clearly over 1975–2011 than over 1948–2011 (not shown but see

FIGURE 4(b) with R3 and R4 for an illustration). This is in agreement with Fig. 3.1 of Trenberth et al. [2007], showing a decrease of temperature between 1940 and the mid 1970s, and an increase later on. Hence, FIGURE 8 shows maps equivalent to those of FIGURE 7 but with trends calculated over 1975–2011.

Comparing the results for 1948–2011 with those for 1975–2011, we have to keep in mind that reanalysis data are sensitive to the changes in the observing system (e.g. satellites and surface observation coverage) around the 1970s. Therefore, the model component in the reanalysis data is necessarily larger before the 1970s. Globally, the trends are more positive over 1975–2011 than over 1948–2011. Regimes 1 and 4 mostly display positive trends while R3 and R4 show both positive and negative evolutions of temperature. One can note the two sub-regions with trends significantly negative: off the eastern US coast around  $60^{\circ}$  W  $\times$   $45^{\circ}$  N (for regimes 1, 2 and 3), and in the Mediterranean Sea (for Regimes 2 and 3). Those two sub-regions also present negative trends over 1948–2011 (FIGURE 7) for all four regimes.

When looking at the global significant trends (i.e. without conditioning by seasonal regimes, last maps of FIGURES 8 and 7), although most positive conditional trends are relatively similar to unconditional ones, the negative conditional slopes are not as visible. We emphasize that the local trends for the four regimes cannot be combined, added up, or averaged to retrieve the unconditional trends. This result shows a seasonal effect of the temporal evolution of temperature that is not captured by unconditional analyses. The same phenomenon is observed when calculating the significant trends of temperature conditionally on the ‘classical’ calendar seasons (not shown).

## 5. Conclusions and perspectives

In conclusion, this paper proposes a novel interpretation of weather seasonality and its trends over the past decades. The presented analysis offers flexibility in season definition that evolves in time. Our approach adapts the season occurrences, from year to year and from day to day, to the large-scale atmospheric situations and, hence, allows to see that the trends in frequency of those ‘seasons’ (i.e. seasonal regimes) are significant over the last decades. Most notably, summer conditions are getting more frequent for all months in May to October during the 1948–2011 time period; and winter-like Z500 conditions are fewer

and fewer for all months in November to April from 1948. We also emphasized that the effects of the changes in atmospheric circulations significantly drive the variability of the length of the seasons, with summers beginning earlier and ending later from 1948 to 2011, while the opposite is observed for winters, implying longer summers and shorter winters in the 2000s than in the 1950s. The temperature responses of the changes in atmospheric circulation do superimpose over the first order changes due to human activities, but can have a modulation if weather regimes evolve with time. Indeed, the temperature trends are strongly seasonal regimes-dependent, with both positive and negative trends according to the sub-regions. As already pointed out in Trenberth et al. [2007], this clearly emphasizes the need to more regional modelling and analyses of temperature trends due to climate change.

An original perspective is to employ this season definition to evaluate climate models on their ability to reproduce those trends in frequency and first or last date, as well as conditional trends of temperature.

Moreover, as the proposed methodology allows to define seasons adapted to large-scale conditions, it has a high potential for ‘season forecasting’. Indeed, based on atmospheric fields from seasonal forecasts, it is possible to project sequences of days onto those regimes (through EQUATION 3) to predict potential early/late upcoming summer or winter. This would be of strong interest to forecast heat waves or droughts – that can be triggered by earlier conditions of the hot season [e.g. Cassou et al., 2005 ; Vautard et al., 2007] – or winter storms – through storm track modifications [e.g. Pinto et al., 2009 ]. Hence, our approach and results can be employed to make long-term projections of phenomena whose frequency depends on the synoptic circulation and surface temperature.

## Acknowledgments

The authors would like to thank Prof. Vincent Moron and the anonymous reviewers for their thorough reading and constructive remarks. This work has been partly supported by the GIS REGYNA and PEPER projects, as well as the ANR McSim project.

### 3. Un outil d'analyse opérationnel ?


Un des apports des travaux menés dans ce chapitre est la possibilité qu'offre notre méthode de clustering de pouvoir projeter les données reflétant les conditions de circulation atmosphérique sur les régimes obtenus. Ainsi, on est en mesure d'attribuer un jour donné à un des régimes saisonniers. Avant de parler de prévision, on peut dans un premier temps s'intéresser à une utilisation dans un contexte d'analyse opérationnelle. En effet, on dispose des régimes obtenus pour la période 1948-2011. Il serait intéressant de regarder pour un jour donné après 2011 à quel régime il appartient. Pour cela, nous avons mis au point un système de représentation polaire  $(r, \theta)$  à partir des ratios de mélange  $\pi_k$  (cf. ÉQUATION 2 de l'article) *a posteriori*. En effet, l'algorithme EM nous donne une probabilité d'appartenance d'une circulation journalière donnée à chacun des régimes. Le jour est attribué au régime pour lequel il a la plus grande probabilité d'appartenance. On obtient la FIGURE V.9 grâce à ces probabilités. Nous avons défini  $(r, \theta)$  pour un jour donné de la façon suivante :

$$\begin{cases} r = 2 * \sqrt{X^2 + Y^2} \\ \theta = 180 * \frac{\tan^{-1}(Y/X)}{\pi} + 180 \end{cases} \quad (\text{V.5})$$


avec  $X = \frac{\pi_2 - \pi_4}{2}$ ,  $Y = \frac{\pi_3 - \pi_1}{2}$  et  $(\pi_1, \pi_2, \pi_3, \pi_4)$  les probabilités journalières d'appartenance à chacun des quatre régimes. Cette représentation graphique permet à la fois de voir quel est le régime de temps du jour en question et également si le RT saisonnier correspond à une des saisons traditionnelles. Dans ces graphiques, le point orange représente la position du régime attribué à une circulation journalière donnée, les autres points étant les régimes attribués aux 14 jours précédents, leur couleur est fonction de leur appartenance à une des saisons traditionnelles : noir pour l'hiver, rouge pour le printemps, vert pour l'automne et bleu pour l'été. Les quatre cadres, noir, rouge, vert et bleu correspondent aux quatre régimes saisonniers.

Par exemple, nous avons pris le cas d'un jour d'été, le 17 septembre 2013, à la FIGURE V.9(a), la circulation de ce jour est néanmoins attribuée au régime R3 alors que, du point de vue astronomique, on s'attend plutôt à une circulation atmosphérique de type estival du régime R4. Dans plusieurs cas, nous constatons des conditions atmosphériques correspondant à un RT différent de celui de la saison traditionnelle. Par exemple, le 13 décembre (FIGURE V.9(b)) à la fin de l'automne présente déjà des conditions atmosphériques hivernales (régime R1). Pour un jour de printemps, le 10 juin 2015 (FIGURE V.9(c)), on constate des conditions de circulation atmosphérique du régime estival (R4) de même que pour le 1er octobre (FIGURE V.9(d)) alors qu'on est déjà en automne.


(a) 17 septembre 2013



(b) 13 décembre 2013



(c) 10 juin 2015



(d) 1 octobre 2015




FIGURE V.9 – Exemples de représentation des régimes auxquels sont attribuées des circulations journalières. Le point orange représente la position du régime attribué à une circulation journalière donnée, les autres points étant les régimes attribués aux 14 jours précédents, leur couleur est fonction de leur appartenance à une des saisons traditionnelles : noir pour l'hiver, rouge pour le printemps, vert pour l'automne et bleu pour l'été. Les quatre cadres, noir, rouge, vert et bleu correspondent aux quatre régimes saisonniers.

Une animation représentant les régimes attribués aux 365 derniers jours est disponible à l'adresse suivante : [http://www-lscedods.cea.fr/seaWR/Anim\\_WR.gif](http://www-lscedods.cea.fr/seaWR/Anim_WR.gif). Celle-ci est mise à jour automatiquement chaque jour.

## 4. Perspectives

Des travaux menés dans ce chapitre découlent quelques perspectives que nous explicitons ici.

Une suite naturelle est l'application de cette définition des saisons aux GCMs ou RCMs et l'évaluation de la capacité des modèles climatiques et régionaux à reproduire ces tendances tant en termes de saisonnalité que de température, sur la même période de temps. Un travail dans un contexte multi-modèles incorporant GCMs et RCMs serait un cadre adapté. On peut également étudier l'évolution future de la saisonnalité à plus long terme à l'aide des projections climatiques issues des GCMs ou des RCMs, en utilisant la même procédure et dans un contexte multi-modèle. On pourrait ainsi étudier la sensibilité de ces tendances aux biais des modèles ainsi que l'influence de la résolution sur elles.

Quelle que soit la méthode de clustering on suppose que la structure de ces régimes n'évolue pas. Un avantage de EM est la possibilité qu'offre cette approche d'évaluer les probabilités d'occurrence des régimes. La probabilité que la situation atmosphérique  $x$  appartienne au régime  $k$  s'écrit de la manière suivante :

$$\tau_k(x) = \frac{\pi_k f_k(x; \alpha_k)}{\sum_{j=1}^K \pi_j f_j(x; \alpha_j)}. \quad (\text{V.6})$$

Cette probabilité nous indique si les structures des RTs sont toujours en adéquation avec les nouvelles situations atmosphériques. Par exemple, des probabilités faibles pour tous les régimes signifient que les RTs historique ne sont plus valides. Ainsi, EM offre la possibilité de vérifier l'hypothèse de stationnarité des régimes dans un contexte de projection climatique.

À la SECTION 3, nous avons présenté un exemple d'utilisation de ces régimes saisonniers. Dans la même veine, on pourrait proposer un système de prévision saisonnière grâce au modèle qui permet d'adapter la définition des saisons aux conditions atmosphériques (*cf.* ÉQUATION 3 de l'article). À l'aide de champs de variables atmosphériques issus de prévisions saisonnières, il est possible de prévoir la précocité ou le retard éventuel d'occurrence d'un type de circulation atmosphérique. On pourrait ainsi davantage exploiter ces prévisions saisonnières et potentiellement avoir une approche différente pour l'évaluation des impacts éventuels.

Ce travail peut également être étendu à d'autres régions et à d'autres variables d'intérêt comme les précipitations dans un contexte de gestion des ressources en eau, par exemple dans le cadre d'études des moussons indienne ou africaine. Cela nécessitera l'ajout de variables de circulation pertinentes pour établir des régimes saisonniers ou intra-saisonniers de précipitations. Dans un contexte de modèle de downscaling statistique, de tels régimes permettraient soit de réduire le nombre de paramètres estimés dans le cas de régimes saisonniers, soit d'affiner la performance de modèles dans le cas de régimes intra-saisonniers. Pour les études menées aux CHAPITRES II et III dans le cadre d'intercomparaisons de modèles statistiques de réduction d'échelle et également pour l'étude menée dans le contexte du modèle spatial introduit au CHAPITRE IV, les calibrations ont été faites de façon saisonnière (deux saisons au CHAPITRE II et quatre au CHAPITRE III) ou mensuelle (CHAPITRE IV). Des calibrations conditionnées par des régimes saisonniers ou intra-saisonniers peuvent remplacer ces calibrations saisonnières ou mensuelles.

## 5. Synthèse des résultats

Dans ce chapitre, les saisons ont été redéfinies à partir de la variabilité de la circulation atmosphérique sur l'Atlantique Nord.

Cela a été réalisé à partir de données de hauteur de géopotential à 500 hPa issues des réanalyses NCEP et de l'algorithme EM pour réaliser un clustering des données. Ainsi, quatre régimes sont obtenus qu'on affecte globalement à quatre périodes/saisons de l'année. On est alors en mesure d'étudier les tendances de fréquence d'occurrence et les tendances de la première et de dernière occurrence des régimes. On s'intéressera en particulier aux jours ayant des conditions de circulation de types hivernales et estivales.

Les principaux résultats montrent une augmentation de la fréquence des jours ayant des conditions estivales durant l'été avec un allongement de l'été (i.e., la première occurrence de ce régime est de plus en plus précoce et la dernière occurrence de plus en plus tardive) dans les années 2000 par rapport aux années 1950. A l'opposé, on observe une baisse de la fréquence d'occurrence des jours aux conditions hivernales en hiver avec un raccourcissement de l'hiver.

Une étude de l'évolution temporelle des températures restreintes aux régimes a été menée. On observe des tendances positives et négatives significatives sur certaines sous-régions du domaine d'étude. Mais cela nécessite une étude plus localisée pour approfondir les résultats.

Ce travail aspire à mettre en place un cadre pour l'analyse de la saisonnalité des régimes de temps applicable pour les GCMs dans un contexte de climat actuel et pour les projections climatiques futures. On pose également les bases potentielles d'un modèle statistique pour exploiter encore davantage les prévisions saisonnières à court terme.

## Références Bibliographiques du Chapitre V

- AILLIOT, Pierre, THOMPSON, Craig & THOMSON, Peter [2009]. "Space-time modelling of precipitation by using a hidden Markov model and censored Gaussian distributions". *Journal of the Royal Statistical Society : Series C (Applied Statistics)*. Vol. 58. no. 3, p. 405–426.
- BARBOSA, S.M., FERNANDES, M.J. & SILVA, M.E. [2005]. "Space-time analysis of sea level in the North Atlantic from TOPEX/Poseidon satellite altimetry". Gravity, Geoid and Space Missions. Sous la dir. de Christopher JEKELI, Luisa BASTOS & Joana FERNANDES. Vol. 129. International Association of Geodesy Symposia. Springer Berlin Heidelberg, p. 248–253.
- BARNSTON, Anthony G. & LIVEZEY, Robert E. [1987]. "Classification, Seasonality and Persistence of Low-Frequency Atmospheric Circulation Patterns". *Monthly Weather Review*. Vol. 115. no. 6, p. 1083–1126.
- BELLONE, Enrica, HUGHES, James P. & GUTTORP, Peter [2000]. "A hidden Markov model for downscaling synoptic atmospheric patterns to precipitation amounts". *Journal of Hydrology*. Vol. 15. no. 1, p. 1–12.
- CASSOU, C. [2008]. "Intraseasonal interaction between the Madden–Julian Oscillation and the North Atlantic Oscillation". *Nature*. Vol. 455, p. 523–527.
- CASSOU, C., TERRAY, L. & PHILLIPS, A.S. [2005]. "Tropical Atlantic Influence on European Heat Waves". *J. Clim.*. Vol. 18 (15), p. 2805–2811.
- CORTI, S., MOLteni, F. & PALMER, T.N. [1999]. "Signature of recent climate change in frequencies of natural atmospheric circulation regimes". *Nature*. Vol. 398, p. 799–802.
- DEMPSTER, A., LAIRD, N. & RUBIN, D. [1977]. "Maximum likelihood from incomplete data via the EM algorithm". *J. Royal. Stat. Soc., Ser. B*. Vol. 39, p. 1–38.
- DONAT, M.G., LECKEBUSCH, G.C., PINTO, J.G. & ULBRICH, U. [2010]. "European storminess and associated circulation weather types : future changes deduced from a multi-model ensemble of GCM simulations". *Climate Research*. Vol. 42, p. 27–43.
- FRALEY, C. & RAFTERY, A. [2002]. "Model-based clustering, discriminant analysis and density estimation". *J. Am. Stat. Assoc.*. Vol. 97, p. 611–631.
- HABERLANDT, U. & RADTKE, I. [2014]. "Hydrological model calibration for derived flood frequency analysis using stochastic rainfall and probability distributions of peak flows". *Hydrology and Earth System Sciences*. Vol. 18. no. 1, p. 353–365.
- HUGHES, James P. & GUTTORP, Peter [1994]. "Incorporating Spatial Dependence and Atmospheric Data in a Model of Precipitation". *Journal of Applied Meteorology*. Vol. 33. no. 12, p. 1503–1515.
- JACOBET, J., WANNER, H., LUTERBACHER, J., BECK, C., PHILIPP, A. & STURM, K. [2002]. "Atmospheric circulation variability in the North-Atlantic-European area since the mid-seventeenth century". *Clim. Dyn.*. Vol. 20. no. 4, p. 341–352.
- KALNAY, E., KANAMITSU, M., KISTLER, R., COLLINS, W., DEAVEN, D., GANDIN, L., IREDELL, M., SAHA, S., WHITE, G., WOOLLEN, J., ZHU, Y., CHELLIAH, M., EBISUZAKI, W., W.HIGGINS, JANOWIAK, J., MO, K. C., ROPELEWSKI, C., WANG, J., LEETMAA, A., REYNOLDS, R., JENNE, R. & JOSEPH, D. [1996]. "The NCEP/NCAR 40-Year Reanalysis Project". *Bulletin of the American Meteorological Society*. Vol. 77 (3), p. 437–471.
- MCLACHLAN, G. & PEEL, D. [2000]. "Finite Mixture Model". New York : Wiley series in probability & statistics.
- MICHELANGELI, P.-A., VAUTARD, R. & LEGRAS, B. [1995]. "Weather regimes : Recurrence and quasi-stationarity". *J. Atmos. Sci.*. Vol. 52, p. 1237–1256.
- MORON, V., ROBERTSON, A. W. & QIAN, J.-H. [2010]. "Local versus regional-scale characteristics of monsoon onset and post-onset rainfall over Indonesia". *Clim. Dyn.*. Vol. 34, 281–299, DOI 10.1007/s00382-009-0547-2.
- PEARSON, K. [1894]. "Contributions to the theory of mathematical evolution". *Philosophical Transactions of the Royal Society of London*. Vol. A 185, p. 71–110.
- PETROW, T., ZIMMER, J. & MERZ, B. [2009]. "Changes in the flood hazard in Germany through changing frequency and persistence of circulation patterns". *Natural Hazards and Earth System Sciences*. Vol. 9 (4), p. 1409–1423.
- PHILIPP, A., BARTHOLY, J., BECK, C., ERPICUM, M., ESTEBAN, P., FETTWEIS, X., HUTH, R., JAMES, P., JOURDAIN, S., KREIENKAMP, F., KRENNERT, T., MICHALIDES, S. Lykoudis S. C., PIANKO-KLUCZYNSKA, K., POST, ALVAREZ, D. R., SCHIEMANN, R., SPEKAT, A. & TYMVIOS, F. S. [2010]. "Cost733cat - a database of weather and circulation type classifications". *Phys Chem Earth (Special Issue)*. Vol. 35, p. 360–373.
- PINTO, J.G., ZACHARIAS, S., FINK, A.H., LECKEBUSCH, G.C. & ULBRICH, U. [2009]. "Factors contributing to the development of extreme North Atlantic cyclones and their relationship with the NAO". *Clim. Dyn.*. Vol. 32, p. 711–737.

- REINHOLD, Brian B. & PIERREHUMBERT, Raymond T. [1982]. “Dynamics of Weather Regimes : Quasi-Stationary Waves and Blocking”. *Monthly Weather Review*. Vol. 110. no. 9, p. 1105–1145.
- RUST, H., VRAC, M., LENGAGNE, M. & SULTAN, B. [2010]. “Quantifying differences in circulation patterns based on probabilistic models : IPCC-AR4 multi-model comparison for the North Atlantic”. *Journal of Climate*. Vol. 23, p. 6573–6589.
- SCHNUR, Reiner & LETTENMAIER, Dennis P [1998]. “A case study of statistical downscaling in Australia using weather classification by recursive partitioning”. *Journal of Hydrology*. Vol. 212–213. no. 0, p. 362–379.
- SCHWARZ, G. [1978]. “Estimating the dimension of a model”. *Ann. Stat.*. Vol. 6, p. 461–464.
- TRENBERTH, K. E., JONES, P. D., AMBENJE, P., BOJARIU, R., EASTERLING, D., TANK, A. Klein, PARKER, D., RAHIMZADEH, F., RENWICK, J. A., RUSTICUCCI, M., SODEN, B. & ZHAI, P. [2007]. “Observations : Surface and Atmospheric Climate Change”. *Climate Change 2007 : The Physical Science Basis. Contribution of Working Group I to the Fourth Assessment Report of the Intergovernmental Panel on Climate Change*. Sous la dir. de S. SOLOMON, D. QIN, M. MANNING, Z. CHEN, M. MARQUIS, K. B. AVERYT, M. TIGNOR & H. L. MILLER. Cambridge, United Kingdom & New York, NY, USA : Cambridge University Press.
- VAUTARD, R., YIOU, P., D’ANDREA, F., NOBLET, N. De, VIOVY, N., CASSOU, C., POLCHER, J., CIAIS, P., KAGEYAMA, M. & FAN, Y. [2007]. “Summertime European heat and drought waves induced by wintertime Mediterranean rainfall deficit”. *Geophys. Res. Lett.*. Vol. 34, L07711.
- VRAC, M. & YIOU, P. [2010]. “Weather regimes designed for local precipitation modeling : Application to the Mediterranean basin”. *J. Geophys. Res.*. Vol. 115, D12103.
- VRAC, M., HAYHOE, K. & STEIN, M. [2007b]. “Identification and inter-model comparison of seasonal circulation patterns over North America”. *Int. J. Climatol.*. Vol. 27(5), p. 603–620.
- VRAC, M., STEIN, M. L. & HAYHOE, K. [2007d]. “Statistical downscaling of precipitation through nonhomogeneous stochastic weather typing”. *Climate Research*. Vol. 34. no. 3, p. 169–184.
- WANG, H.L., SCHUBERT, S., SUAREZ, M., CHEN, J.Y., HOERLING, M., KUMAR, A. & PEGION, P. [2009]. “Attribution of the Seasonality and Regionality in Climate Trends over the United States during 1950-2000”. *J. Clim.*. Vol. 22, p. 2571–2590.
- WILKS, Daniel S. [2012]. “Stochastic weather generators for climate-change downscaling, part II : multivariable and spatially coherent multisite downscaling”. *Wiley Interdisciplinary Reviews : Climate Change*. Vol. 3. no. 3, p. 267–278.
- YIOU, P. & NOGAJ, M. [2004]. “Extreme climatic events and weather regimes over the North Atlantic : When and where?” : *Geophysical Research Letters*. Vol. 31. no. 7.
- ZUCCHINI, Walter & GUTTORP, Peter [1991]. “A Hidden Markov Model for Space-Time Precipitation”. *Water Resources Research*. Vol. 27. no. 8, p. 1917–1923.
- ZVERYAEV, I.I. [2006]. “Seasonally varying modes in long-term variability of European precipitation during the 20th century”. *Journal of Geophysical Research - Atmospheres*. Vol. 111.





---

## Conclusions & Perspectives.

Où l'on rappelle les principales conclusions de ce travail et où on discute certaines perspectives.

---

1. Retour sur les motivations.....	172
2. Conclusions principales.....	173
2.1. Résultats des intercomparaisons . . . . .	173
2.2. Résultats du travail sur la non-stationnarité . . . . .	175
3. Perspectives.....	177
3.1. Perspectives méthodologiques . . . . .	177
3.2. Consistance physique et extension géographique . . . . .	179

---

## 1. Retour sur les motivations

Quelle que soit la région ou la période d'étude, il est désormais nécessaire d'obtenir des simulations fiables de variables climatiques à haute résolution afin entre autres d'étudier le climat et le changement climatique et d'en anticiper autant que possible les conséquences pour l'homme. En fonction des applications, les besoins essentiels sont une bonne représentation des intensités (des précipitations et des températures), une bonne variabilité spatiale et temporelle et une bonne consistance des variables à l'échelle locale. Cela est notamment essentiel pour l'étude de scénarios futurs. Pour répondre à ces besoins particuliers, un effort considérable a été fait pour développer les modèles de régionalisation dynamiques et statistiques.

Il existe quelques initiatives qui ont eu pour but de coordonner ces efforts notamment pour inter-comparer et évaluer les incertitudes des différents modèles (par exemple PRUDENCE, ENSEMBLES et CORDEX). Ces initiatives se sont essentiellement focalisées sur les modèles dynamiques et on constate un manque de représentativité des modèles statistiques au sein de ces initiatives. Cette lacune soulève plusieurs questions sans réponse. Les travaux de cette thèse propose de répondre en partie à certaines d'entre elles qui sont les suivantes :

- i. Certaines études ponctuelles ont été réalisées avec quelques modèles de downscaling statistiques (Statistical Downscaling Models, SDM) et modèles climatiques régionaux (Regional Climate Models, RCM), et il manquait néanmoins une unité dans la façon de considérer ces modèles soit par l'utilisation de prédicteurs ou de résolutions différents, soit par l'omission de certains types de modèles de régionalisation.
- ii. Dans un contexte de downscaling statistique, les simulations sont réalisées en considérant que les prédicteurs issus des réanalyses et des modèles de climat globaux (Global Climate Model, GCM) reflètent parfaitement la circulation à grande échelle que ce soit dans un contexte de climat présent ou futur. La question est de savoir si cela est valide et dans le cas contraire quelle est l'influence des biais des GCMs sur la réduction d'échelle.
- iii. Alors que la formulation mathématique des SDMs est stationnaire dans le temps, la question est de savoir dans un contexte de climat non-stationnaire, ce qui est le cas dans un contexte de changement climatique ou de variabilité climatique en général, comment dans un premier temps, caractériser cette non-stationnarité dans la circulation à grande échelle. Dans un second temps, les apports d'un modèle de downscaling statistique pour la prise en compte de la non-stationnarité dans un contexte de modèle spatial sont étudiés.

En réponse à ces questions qui renvoient, d'une part, à la nécessité d'améliorer nos connaissances en termes de modèles de régionalisation statistiques, et d'autre part, au développement d'un nouveau modèle spatial et d'une nouvelle méthode d'analyse des modèles et de la variabilité climatique, le présent travail de thèse s'était fixé trois objectifs principaux :

- i. Avoir une meilleure connaissance des modèles de régionalisation pour une meilleure utilisation. Cela a été abordé sous deux angles :
  - la mise en oeuvre d'une intercomparaison incluant des modèles de régionalisation statistiques et dynamiques pour les précipitations dans un cadre d'évaluation en climat présent ;

- l'évaluation de l'impact des biais des GCMs sur les modèles de régionalisation statistiques en climat historique et futur pour les précipitations et les températures.
- ii. Développer un modèle spatial de réduction d'échelle statistique intégrant la non-stationnarité spatiale et temporelle du climat.
- iii. Définir les saisons à partir de régimes de circulation atmosphérique.

Tous les résultats principaux de cette thèse seront rappelés dans la prochaine section. Un certain nombre de questions méthodologiques et climatologiques en découleront et seront discutées dans la SECTION 3, conduisant à identifier des axes de recherches pour les années à venir.

## 2. Conclusions principales

### 2.1. Résultats des intercomparaisons

Étant donné la faible prise en compte des modèles de downscaling statistiques dans les études d'intercomparaison de modèles, nous avons proposé un cadre de travail permettant à la fois de comparer modèles statistiques et dynamiques, ayant des approches conceptuelles très différentes, de façon aussi équitable que possible à l'aide d'indicateurs statistiques. Ce cadre de travail requerrait les trois conditions principales suivantes : jeu de données de prédicteurs unique, résolution unique et représentation de toutes les familles de modèles de downscaling. L'intercomparaison a été menée au CHAPITRE II et nous en déduisons le résultat principal suivant : il est difficile de déterminer le "meilleur" modèle. Les résultats de l'intercomparaison dépendent quasi-entièrement des indicateurs choisis et en particulier du domaine scientifique considéré et des besoins de l'utilisateur. Ce travail propose une manière pour l'utilisateur de choisir le type de simulations/modèles le plus adapté à ses besoins.

#### *COST Action : Value / CORDEX-ESD*

Comme évoqué dans l'article à la SECTION 2, deux initiatives ayant partiellement les mêmes objectifs que les travaux menés au CHAPITRE II sont actuellement en cours. Ces initiatives ont notamment pour but la coordination d'intercomparaisons de SDMs à l'échelle continentale pour à terme les comparer avec les RCMs. Ce sont les initiatives CORDEX-ESD<sup>1</sup>, et la COST Action VALUE<sup>2</sup>. Mathieu Vrac, mon directeur de thèse, et moi même avons contribué à ces initiatives en leur fournissant des simulations.

Nous allons rapidement décrire le protocole expérimental de ces deux initiatives.

---

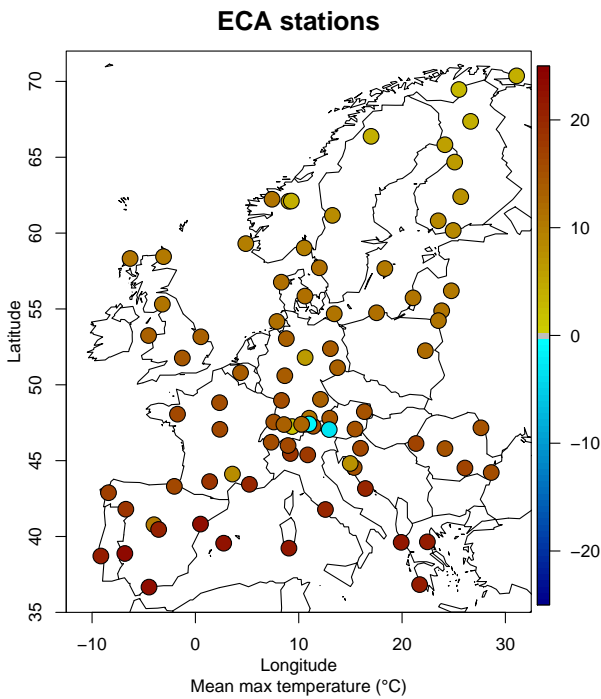
1. <http://wcrp-cordex.ipsl.jussieu.fr/index.php/community/cordex-esd>

2. <http://www.value-cost.eu/>. Le cadre et les motivations de cette initiative sont décrits dans MARAUN et al. [2015].

	COST Action : Value	CORDEX-ESD
Expérience	1.a/1.b	1
Prédicands	86 stations	81 stations
	ECA, KLEIN TANK et al. [2002]	Clarís LPB, PENALBA et al. [2014]
	Tmin, Tmoy, Tmax, PR	Tmin, Tmax, PR
Région	EURO-CORDEX	Argentine
Prédicteurs	ERA-Interim : Idem Article	ERA-Interim : Idem Article

Tableau VI.1 – Tableau récapitulant les protocoles de VALUE et CORDEX-ESD. Pour l’expérience 1.b de VALUE, on remplace les observations aux stations par les points de grille les plus proches issues des données grillées E-OBS à la résolution 0.22°. Pour CORDEX-ESD, les prédicteurs sont choisis sur la zone géographique englobant le région amérique du sud telle définie dans CORDEX.

(a) Température maximale – VALUE



(b) Température maximale – CORDEX-ESD




FIGURE VI.1 – Valeur moyenne des températures maximales aux stations utilisées dans VALUE et CORDEX ESD

Plus de détails sont disponibles sur le site de VALUE et de CORDEX-ESD notamment en ce qui concerne la validation-croisée.

Un des buts des modèles de régionalisation est aussi de pouvoir fournir des simulations à haute résolution à partir des projections climatiques issues des GCMs. Une des hypothèses implicites pour l'application des modèles de downscaling statistiques est que les variables à grande échelle sont correctement représentées et pertinentes aussi bien dans les GCMs que dans les réanalyses (*cf.* CHAPITRE I, SECTION 3.3, hypothèse C). Pour tester cette hypothèse, une méthodologie a été mise en place. Cette dernière consiste à utiliser une procédure de correction de biais des GCMs par rapport aux réanalyses servant à la calibration des SDMs. Le CHAPITRE III décrit les résultats de ce test dans le cadre d'intercomparaisons de SDMs uniquement et cela en climat CTRL et futur. Trois tests sont réalisés :

- un test en climat CTRL : pour déterminer l'influence de la correction de biais sur les simulations issues des SDMs ;
- un test d'évolution : pour déterminer l'influence de la correction de biais sur l'évolution future des simulations issues des SDMs ;
- un test de stationnarité : pour évaluer la stationnarité temporelle des changements apportés par la correction de biais entre la période historique (CTRL) et future.

Il s'avère que les résultats des simulations sont largement influencés par cette correction de biais pour l'ensemble de ces trois tests (différemment en fonction des variables d'intérêt et du modèle de downscaling), remettant en cause l'hypothèse C.

## 2.2. Résultats du travail sur la non-stationnarité

### 2.2.1. Résultats du travail de développement d'un modèle spatial.

Le cadre des processus spatiaux méta-gaussiens offre la possibilité de prendre en compte la non-stationnarité spatiale et temporelle dans le développement d'un modèle spatial de downscaling. Un modèle spatial consiste dans notre cas à estimer une ou plusieurs lois marginales et une fonction de covariance.

Après avoir testé 14 variantes d'un modèle spatial, nous avons les résultats principaux suivants :

- on constate un apport indéniable de l'utilisation simultanée des covariables spatiales et temporelles dans la loi marginale et la fonction de covariance dans la bonne prise en compte de la non-stationnarité ;
- on constate néanmoins un biais assez important en terme de fréquence de jours de pluie et de biais moyen qu'il nous faut améliorer.

Les travaux menés au CHAPITRE IV dans ce sens permettent de mettre en évidence l'apport des covariables temporelles dans la modélisation spatiale et les résultats sont très encourageants. Un article devrait être soumis sur ces résultats au printemps 2016.

### 2.2.2. Régimes de temps saisonniers

La définition des saisons par des régimes de circulation du CHAPITRE V nous permet d'étudier la non-stationnarité (ou variabilité) temporelle, en particulier saisonnière des conditions de circulation

atmosphérique. On est en mesure de caractériser la variabilité et les tendances saisonnières. Ainsi on observe, de mai à octobre, une augmentation du nombre de jours aux conditions de circulation estivales alors que celui des jours aux conditions hivernales diminue de novembre à avril sur la période 1948-2011. Nous avons également mis en évidence que les étés sont plus longs et les hivers plus courts dans les années 2000 que dans les années 1950. Les températures conditionnelles aux régimes de temps (RT) ont des tendances significatives positives ou négatives en fonction de la sous-région considérée.

#### Outil opérationnel

Un outil d'analyse opérationnel d'identification du régime de circulation d'un jour donné a été mis en place. Il permet à la fois de voir quel est le régime de temps du jour en question et également si le RT saisonnier correspond à une des saisons traditionnelles.

## 3. Perspectives

Pour chacun des chapitres, nous avons donné des perspectives spécifiques. Il reste néanmoins des perspectives plus générales à l'ensemble de ces chapitres. Les questions posées suite à ce travail sont de deux ordres. Les premières ont trait aux travaux menés dans ce manuscrit en termes de modèles et méthodes statistiques. Les secondes concernent plutôt des activités en amont et en aval des travaux de cette thèse et qui permettront de nuancer et peut-être même de consolider les résultats obtenus.

### 3.1. Perspectives méthodologiques

Une large part des travaux a été réalisée dans un cadre d'intercomparaison. Un des buts principaux était d'établir un cadre de travail unique dans lequel peuvent s'évaluer RCMs et SDMs et cela dans un contexte *hindcast* en climat présent. Il serait naturel d'étendre ces travaux en incorporant l'analyse du comportement des modèles en climat futur et pour d'autres variables. En effet, les modèles comparés au CHAPITRE II ont été discriminés d'un point de vue uniquement climatique en termes de propriétés statistiques des précipitations. Il serait bon d'en connaître le comportement dans le futur pour les précipitations et les températures. On peut pour cela compléter ce qui a été amorcé au CHAPITRE III et qui consiste à réaliser des projections sur les périodes CTRL ou futur à partir des modèles calibrés sur des réanalyses. Il faudrait également étendre le jeu d'indicateurs utilisés en incluant des indicateurs multi-variables ou d'autres indicateurs prenant en compte plus spécifiquement les propriétés extrêmes des sorties de simulations [BÜRGER et al., 2012b; BÜRGER et al., 2012a].

Il existe une autre approche permettant d'évaluer les SDMs dans un contexte de climat futur et de réaliser des projections climatiques à partir des GCMs. Celle-ci est basée sur l'idée que les projections réalisées à partir des RCMs peuvent être considérées comme des pseudo-observations [VRAC et al., 2007a]. Ainsi les RCMs servent à la fois de données de référence et à la calibration des modèles à partir des GCMs en climat CTRL. Celle-ci a été appliquée dans un contexte d'intercomparaison et s'avère tout à fait pertinente [cf. GAITAN et al., 2014 pour une application dans un contexte d'intercomparaison].

Une étude d'incertitude pourrait également être une perspective pertinente à mener dans le cadre d'une approche ensembliste. Il existe des études multi-modèles axées uniquement sur les RCMs [TEBALDI et al., 2005], il faut désormais y ajouter des SDMs. Les méthodes ensemblistes cherchent à caractériser de façon probabiliste l'incertitude liée aux modèles dans les projections climatiques. L'étude d'incertitude peut se décliner de plusieurs façons dans le cas du downscaling. On peut par exemple étudier la propagation de l'incertitude des GCMs durant le processus de downscaling [SACHINDRA et al., 2014]. On peut également s'inspirer de TEBALDI et al. [2005] (il existe d'autres approches) pour donner la meilleure simulation possible obtenue en pondérant différents modèles de downscaling (RCMs et SDMs).

Une autre façon de discriminer les modèles de régionalisation peut également se faire par le filtre de la modélisation d'impacts. On peut par exemple, comparer des sorties d'un modèle hydrologique forcé par différents modèles de downscaling. Les travaux menés dans cette thèse ont contribué à ce genre d'étude et un article comparant des modèles statistiques est en cours de révision [GROUILLET et al.,



2015]. Dans ces travaux, nous avons fourni en entrée d'un modèle hydrologique des simulations de précipitations et de températures issues de plusieurs SDMs en climat présent. Le modèle hydrologique a été forcé par des SDMs dont les prédicteurs sont issus des réanalyses NCEP et de deux GCMs. Les simulations hydrologiques, et donc les SDMs de façon indirecte, sont comparées en termes d'indicateurs hydrologiques (*cf.* <http://www.hydrol-earth-syst-sci-discuss.net/12/10067/2015/hessd-12-10067-2015.html>). Il est également possible de considérer d'autres types d'impacts comme l'écologie ou l'agriculture [OETTLI et al., 2011] pour discriminer ces modèles.

Le CHAPITRE III pose la question de la bonne représentation des prédicteurs dans les modèles de climat globaux (hypothèse C de l'introduction). En effet, il existe des biais dans les GCMs. Dans ce chapitre, une seule procédure de correction de biais des prédicteurs issus de deux GCMs a été mise en place. Les perspectives dans ce cadre-là sont multiples. En effet, nous n'avons utilisé qu'une seule méthode de correction de biais. Une étude réunissant plusieurs méthodes de correction de biais est sans doute nécessaire pour obtenir une vue d'ensemble de l'effet de cette correction sur les sorties des modèles statistiques. Dans une perspective similaire, il serait intéressant d'incorporer un plus grand nombre de GCMs. Pour revenir à un contexte où l'on compare RCMs et SDMs, corriger les données GCMs en entrée des RCMs permettrait d'en évaluer les conséquences sur les RCMs et de comparer cela aux effets sur les SDMs [pour des applications sur les RCMs voir, COLETTE et al., 2012; BRUYÈRE et al., 2014].

Toujours dans le cadre des travaux menées au CHAPITRE III, le test de stationnarité mené dans ce contexte ne remet pas en cause uniquement l'hypothèse C mais également l'hypothèse A qui suppose que les liens grande échelle / petite échelle restent valides en cas de changement climatique. En effet, la correction des biais des GCMs fait varier l'évolution des simulations en climat futur par rapport au climat présent par rapport à l'évolution des simulations sans correction. Il y a sans doute une part de cette variation imputable à la correction. Mais il se peut que cela vienne aussi de l'évolution des liens statistiques eux-mêmes entre la calibration et la projection, c'est-à-dire que la nature même des liens peut évoluer. Il est possible que les relations mathématiques soient par exemple linéaires au moment de la calibration mais que cela ne soit plus valide au moment de la projection et deviennent non-linéaires. Cela n'a pas été étudié dans ce manuscrit mais il s'agit d'une piste de travail intéressante.

Le modèle spatial de downscaling statistique a été développé pour répondre au besoin de correctement représenter la non-stationnarité spatiale et temporelle dans un modèle spatial. Les résultats nous portent à croire que les développements menés au CHAPITRE IV sont pertinents. Néanmoins, les biais importants en termes de fréquence de jours de pluie et en intensité moyenne laissent entrevoir des améliorations nécessaires à court terme. Nous rappelons que la loi marginale (en particulier la probabilité d'occurrence des précipitations et les paramètres de la distribution gamma) a été estimée dans le contexte d'un modèle linéaire généralisé (GLM), c'est-à-dire que l'on suppose un lien entre les paramètres de la distribution du prédicteur et des prédicteurs de nature linéaire. Si cette hypothèse est fautive, cela causera forcément des biais importants. Le test réalisé dans les perspectives de ce chapitre révèle une forte non-linéarité de la dépendance prédicteur / prédicteurs et oriente plutôt l'utilisation d'un modèle GAM dans l'estimation de la loi marginale.

Une suite possible aux travaux développés au CHAPITRE V est l'application de la définition des saisons aux GCMs et RCMs afin d'étudier leur comportement en termes de saisonnalité et de tendance

de température conditionnelle sur la période historique. On peut également étudier l'évolution future de la saisonnalité à plus long terme grâce aux projections futures. La formulation mathématique de notre méthode de clustering permet potentiellement une utilisation originale des prévisions saisonnières en projetant les champs de variables atmosphériques issues de prévisions saisonnières sur les régimes obtenus. Ainsi on pourrait par exemple, prévoir une arrivée potentielle précoce ou tardive des conditions estivales ou hivernales. Ceci serait aussi très intéressant pour établir des prévisions de vagues de chaleur ou de sécheresses potentiellement provoquées par des conditions précoces de la saison estivale.

### 3.2. Consistance physique et extension géographique

L'ensemble des travaux menés dans cette thèse est bien sûr reproductible sur une autre région et pour d'autres variables d'intérêt à condition de disposer des données nécessaires à cela en terme de prédictors et d'observations. Il se pose alors la question de la pertinence et de la cohérence des variables physiques. On parle de pertinence notamment lors du choix des prédictors en fonction de la variable d'intérêt. Le problème de cohérence spatiale et temporelle des variables se pose à deux niveaux. Il nous faut faire attention à ne pas briser la cohérence entre les différents prédictors lors de l'étape de pré-traitement (e.g., une ACP ou une correction) de ces derniers en amont des modèles de régionalisation. Ensuite, en aval des modèles de downscaling, il faut faire attention à ce que le processus de régionalisation ne brise pas la cohérence entre les variables simulées.

Dans ce manuscrit, le choix des prédictors est relativement peu discuté. Nous avons mis en place une discussion à ce sujet spécifique aux précipitations issues de EOBS au CHAPITRE II. Et ensuite nous avons gardé les variables choisies pour tous les modèles de downscaling et quelle que soit la période de temps climatique en adaptant le jeu de prédictors pour les températures et le modèle spatial. Il faut tout de même garder à l'esprit que ces prédictors ne sont pas forcément optimaux pour toutes les applications menées dans cette thèse. Une piste pour améliorer cela serait d'étudier les processus physiques pilotant les précipitations et les températures dans les RCMs pour choisir les meilleurs prédictors.

En termes de cohérence des variables physiques, il y a de nombreux aspects à considérer. Premièrement, il faut considérer la cohérence temporelle des prédictors. En effet, dans l'ensemble de la thèse nous avons réalisé des divisions saisonnières (deux ou quatre selon l'étude) ou mensuelles pour la calibration des modèles de façon plus ou moins arbitraire. Or, il serait sans doute judicieux et bien plus optimal statistiquement de réaliser des calibrations conditionnées par des régimes de circulation ou de précipitation. Ainsi les travaux réalisés au CHAPITRE V permettraient, modulo quelques améliorations et adaptations en fonction de la région et de la variable d'intérêt, de conditionner l'ensemble des modèles de downscaling de ce manuscrit. On aurait ainsi une meilleure cohérence des prédictors dans la calibration des modèles.

Un autre aspect est la cohérence inter-variable aussi bien des prédictors que des sorties de simulations. Dans les prédictors, la question se pose notamment au CHAPITRE III lorsque nous corrigeons les prédictors. La correction des prédictors s'est faite variable par variable et peut ainsi remettre en cause la cohérence des prédictors entre eux (spatialement et temporellement). Une solution existe désormais et permet de corriger différentes variables simultanément [VRAC & FRIEDERICH, 2015]. Il se pose aussi la question de la cohérence inter-variable en sorties des SDMs.

Nous avons en effet simulé précipitations et températures séparément. Il se peut que ces variables physiques ne soient plus cohérentes après downscaling, ce qui peut largement influencer les simulations des modèles d'impacts utilisant ces simulations en tant que données d'entrée [WHITE & TOUMI, 2013]. On peut par exemple voir cela en regardant si la relation de Clausius-Clapeyron impliquant température et précipitation est vérifiée ou non [e.g., PANTHOU et al., 2015]. Une correction multivariée *a posteriori* des sorties issues du downscaling [VRAC & FRIEDERICH, 2015] permettrait de rétablir cette cohérence. Une autre solution serait de réaliser un downscaling multivarié tenant compte des interactions entre les variables. C'est une des perspectives à long terme du modèle spatial du CHAPITRE IV.

Toutes ces perspectives représentent une quantité de travail bien plus importante que l'ensemble des travaux menés dans ce manuscrit. Ceci donne un aperçu de la fertilité des travaux menés dans cette thèse qui met en place des pistes de recherche pour l'avenir.

## Références Bibliographiques du Chapitre VI

- BRUYÈRE, C. L., DONE, J. M., HOLLANDA, G. J. & FREDRICK, S. [2014]. “Bias corrections of global models for regional climate simulations of high-impact weather”. *Climate Dynamics*. Vol. 43, p. 1847–1856.
- BÜRGER, G., SOBIE, S. R., CANNON, A. J., WERNER, A. T. & MURDOCK, T. Q. [2012a]. “Downscaling Extremes : An Intercomparison of Multiple Methods for Future Climate”. *Journal of Climate*. Vol. 26. no. 10, p. 3429–3449.
- BÜRGER, G., MURDOCK, T. Q., WERNER, A. T., SOBIE, S. R. & CANNON, A. J. [2012b]. “Downscaling Extremes—An Intercomparison of Multiple Statistical Methods for Present Climate”. *Journal of Climate*. Vol. 25. no. 12.
- COLETTE, A., VAUTARD, R. & VRAC, M. [2012]. “Regional climate downscaling with prior statistical correction of the global climate forcing”. *Geophysical Research Letters*. Vol. 39, L13707, doi :10.1029/2012GL052258.
- GAITAN, Carlos F., HSIEH, William W. & CANNON, Alex J. [2014]. “Comparison of statistically downscaled precipitation in terms of future climate indices and daily variability for southern Ontario and Quebec, Canada”. *Climate Dynamics*. P. 1–17.
- GROUILLET, B., RUELLAND, D., VAITTINADA AYAR, P. & VRAC, M. [2015]. “Sensitivity analysis of runoff modeling to statistical downscaling models in the western Mediterranean”. *Hydrology and Earth System Sciences Discussions*. Vol. 12. no. 10, p. 10067–10108.
- KLEIN TANK, A. M. G., WIJNGAARD, J. B., KÖNNEN, G. P., BÖHM, R., DEMARÉE, G., GOCHEVA, A., MILETA, M., PASHIARDIS, S., HEJKRLIK, L., KERN-HANSEN, C., HEINO, R., BESSEMOULIN, P., MÜLLER-WESTERMEIER, G., TZANAKOU, M., SZALAI, S., PÁLSDÓTTIR, T., FITZGERALD, D., RUBIN, S., CAPALDO, M., MAUGERI, M., LEITASS, A., BUKANTIS, A., ABERFELD, R., ENGELEN, A. F. V. van, FORLAND, E., MIETUS, M., COELHO, F., MARES, C., RAZUVAEV, V., NIEPLOVA, E., CEGNAR, T., ANTONIO LÓPEZ, J., DAHLSTRÖM, B., MOBERG, A., KIRCHHOFFER, W., CEYLAN, A., PACHALIUK, O., ALEXANDER, L. V. & PETROVIC, P. [2002]. “Daily dataset of 20th-century surface air temperature and precipitation series for the European Climate Assessment”. *International Journal of Climatology*. Vol. 22. no. 12, p. 1441–1453.
- MARAUN, Douglas, WIDMANN, Martin, GUTIÉRREZ, José M., KOTLARSKI, Sven, CHANDLER, Richard E., HERTIG, Elke, WIBIG, Joanna, HUTH, Radan & WILCKE, Renate A.I. [2015]. “VALUE : A framework to validate downscaling approaches for climate change studies”. *Earth’s Future*. Vol. 3. no. 1, p. 1–14.
- OETTLI, Pascal, SULTAN, Benjamin, BARON, Christian & VRAC, Mathieu [2011]. “Are regional climate models relevant for crop yield prediction in West Africa?” : *Environmental Research Letters*. Vol. 6. no. 1, p. 014008.
- PANTHOU, G., VRAC, M., DROBINSKI, P., BASTIN, S. & LI, L. [2015]. “Impact of model resolution and Mediterranean sea coupling on hydrometeorological extremes in RCMs in the frame of HyMeX and MED-CORDEX”. *Submitted to Climate Dynamics*.
- PENALBA, Olga C., RIVERA, Juan A. & PÁNTANO, Vanesa C. [2014]. “The CLARIS LPB database : constructing a long-term daily hydro-meteorological dataset for La Plata Basin, Southern South America”. *Geoscience Data Journal*. Vol. 1. no. 1, p. 20–29.
- SACHINDRA, D. A., HUANG, F., BARTON, A. F. & PERERA, B. J. C. [2014]. “Multi-model ensemble approach for statistically downscaling general circulation model outputs to precipitation”. *Quarterly Journal of the Royal Meteorological Society*. Vol. 140. no. 681, p. 1161–1178.
- TEBALDI, Claudia, SMITH, Richard L., NYCHKA, Doug & MEARNS, Linda O. [2005]. “Quantifying Uncertainty in Projections of Regional Climate Change : A Bayesian Approach to the Analysis of Multimodel Ensembles”. *Journal of Climate*. Vol. 18. no. 10, p. 1524–1540.
- VRAC, M., STEIN, M. L., HAYHOE, K. & LIANG, X.-Z. [2007a]. “A general method for validating statistical downscaling methods under future climate change”. *Geophysical Research Letters*. Vol. 34. no. 18.
- VRAC, Mathieu & FRIEDERICH, Petra [2015]. “Multivariate—Intervariable, Spatial, and Temporal—Bias Correction”. *Journal of Climate*. Vol. 28. no. 1, p. 218–237.
- WHITE, R. H. & TOUMI, R. [2013]. “The limitations of bias correcting regional climate model inputs”. *Geophysical Research Letters*. Vol. 40. no. 12, p. 2907–2912.



---

## **ANNEXES**

---






---

## Matériel supplémentaire chapitre II

---



---

### Liste des figures

A.1	Wet Day Frequency Bias – Winter . . . . .	186
A.2	Mean Wet and Dry Spells Bias – Winter . . . . .	186
A.3	Brier Score – Winter . . . . .	187
A.4	Mean Precipitation Bias – Winter . . . . .	187
A.5	Variance Ratio – Winter . . . . .	188
A.6	Q99 Bias – Winter . . . . .	188
A.7	First EOF – Winter . . . . .	189
A.8	Autocorrelation lag 1 – Winter . . . . .	190
A.9	RMSE . . . . .	191

### Liste des tableaux

A.1	Score table winter MEDCORDEX . . . . .	192
A.2	Score table winter EUROCORDEX . . . . .	193
A.3	Figure range for summer . . . . .	194
A.4	Figure range for winter . . . . .	194

---



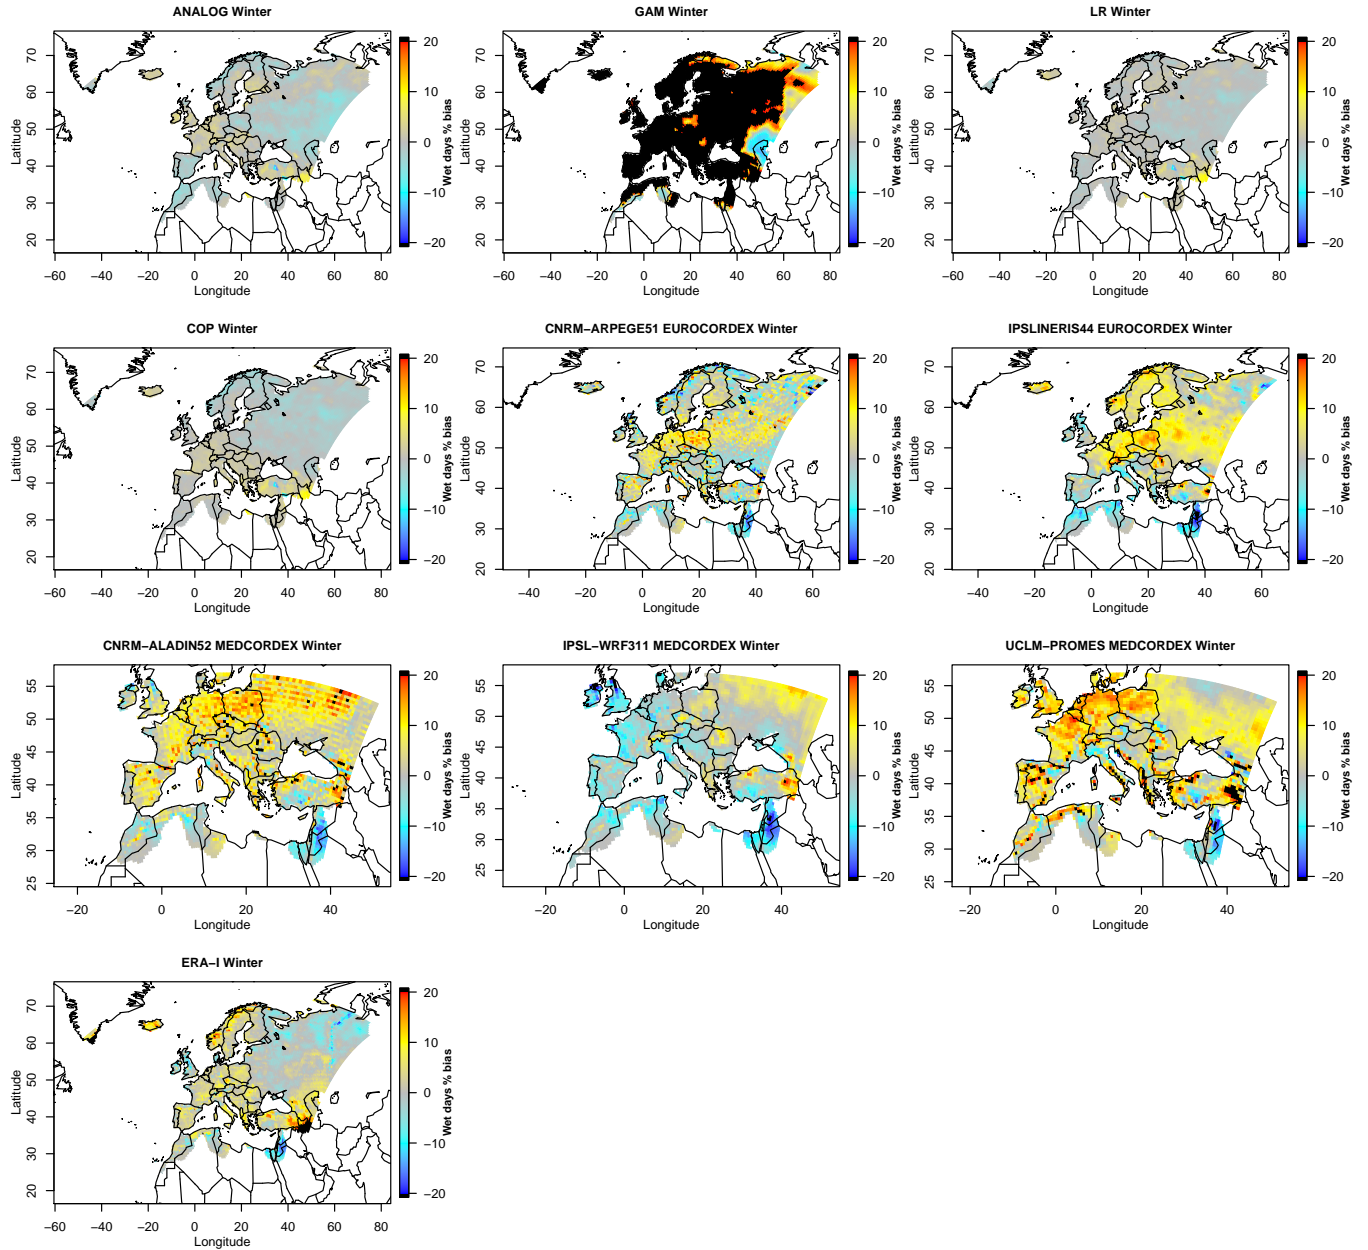


FIGURE A.1 – Idem FIGURE 3 for Winter




FIGURE A.2 – Idem FIGURE 4 for Winter

### Brier Score (Winter)




FIGURE A.3 – Idem FIGURE 5 for Winter

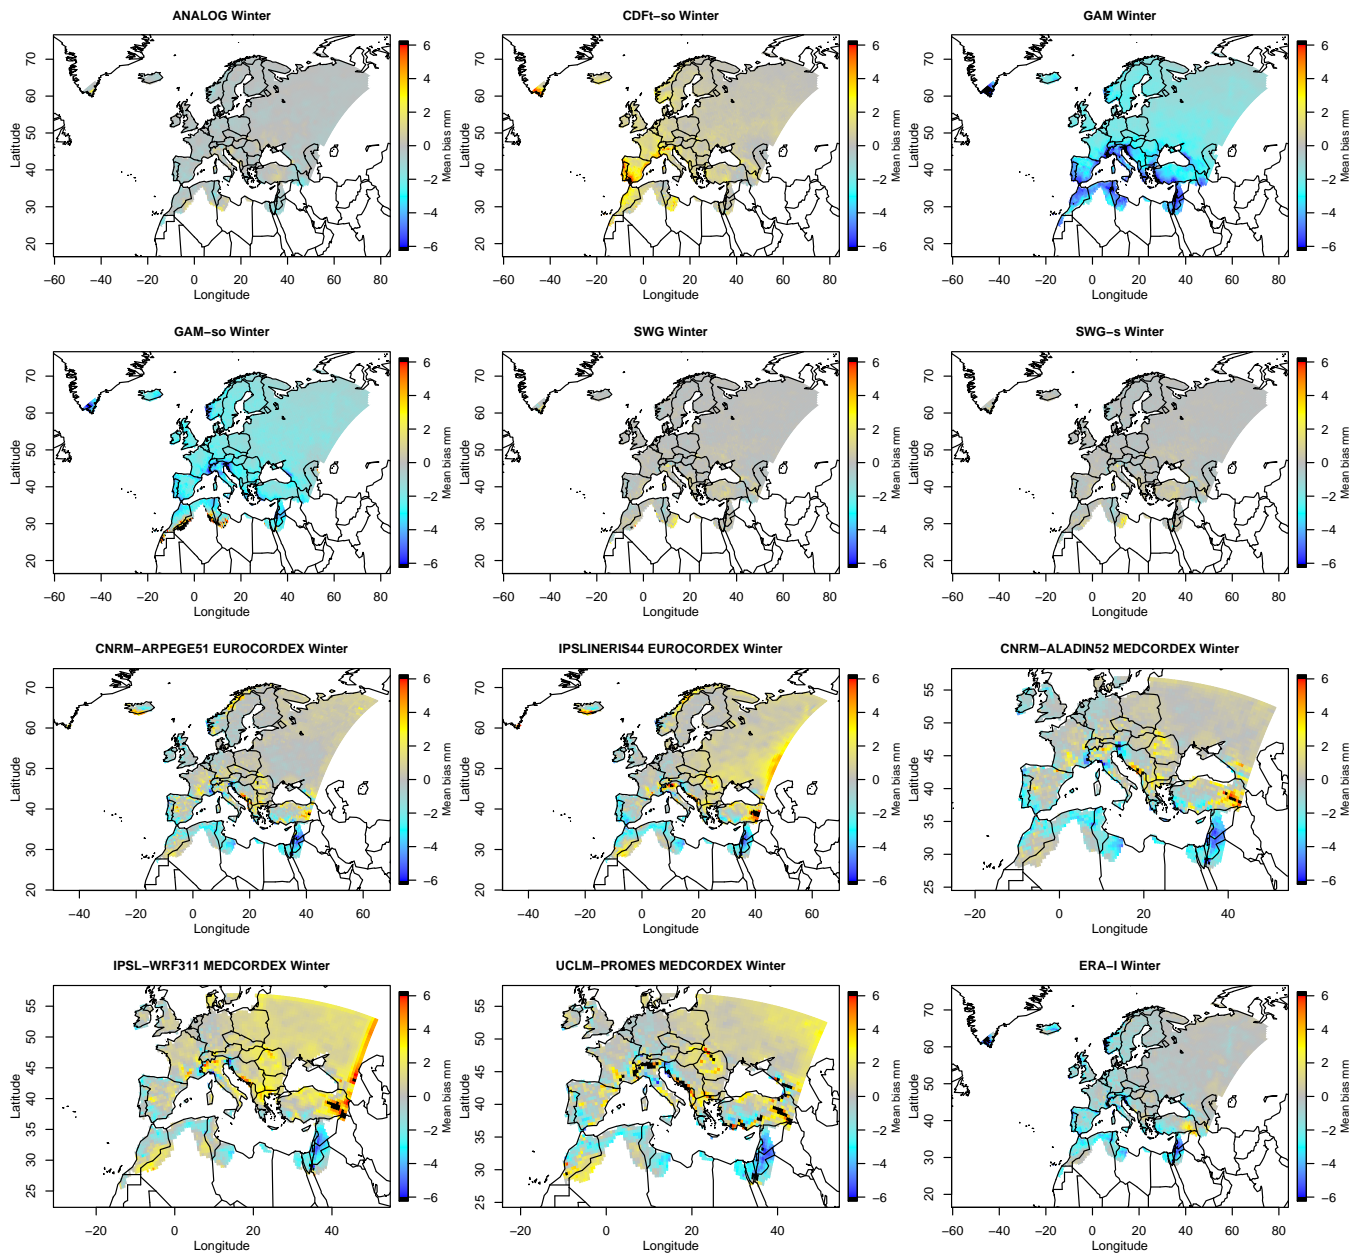


FIGURE A.4 – Idem FIGURE 6 for Winter

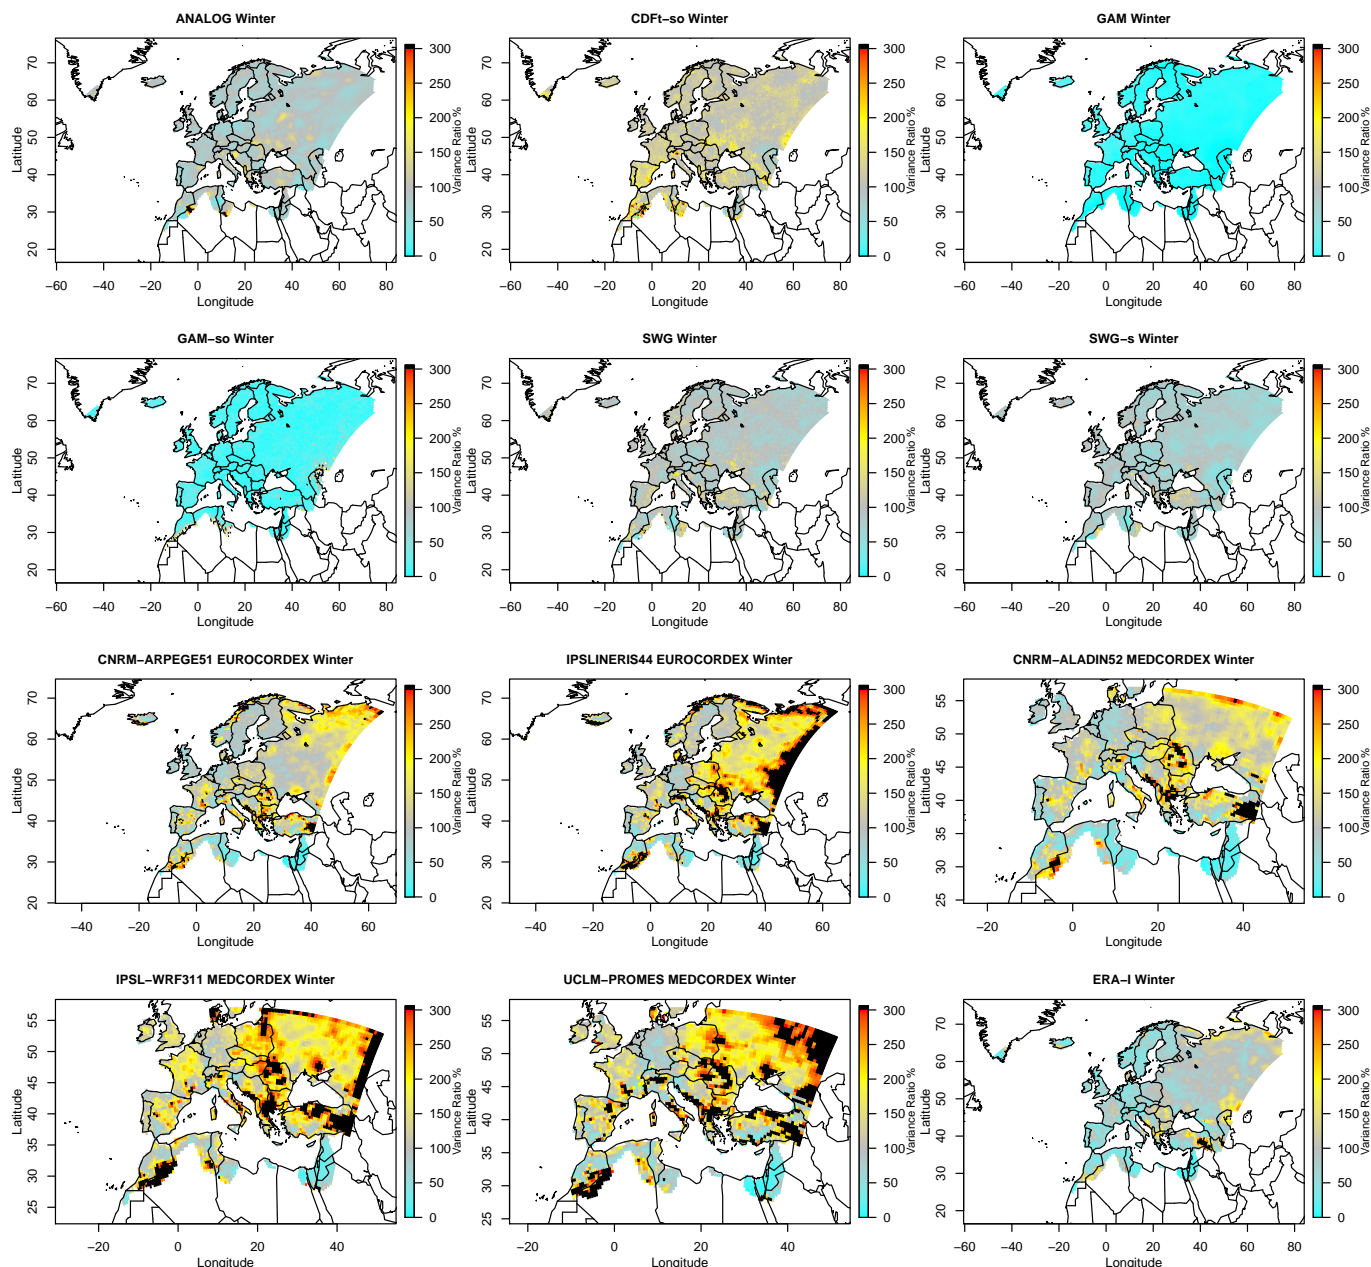


FIGURE A.5 – Idem FIGURE 7 for Winter

### Q99 Bias (Winter)




FIGURE A.6 – Idem FIGURE 8 for Winter

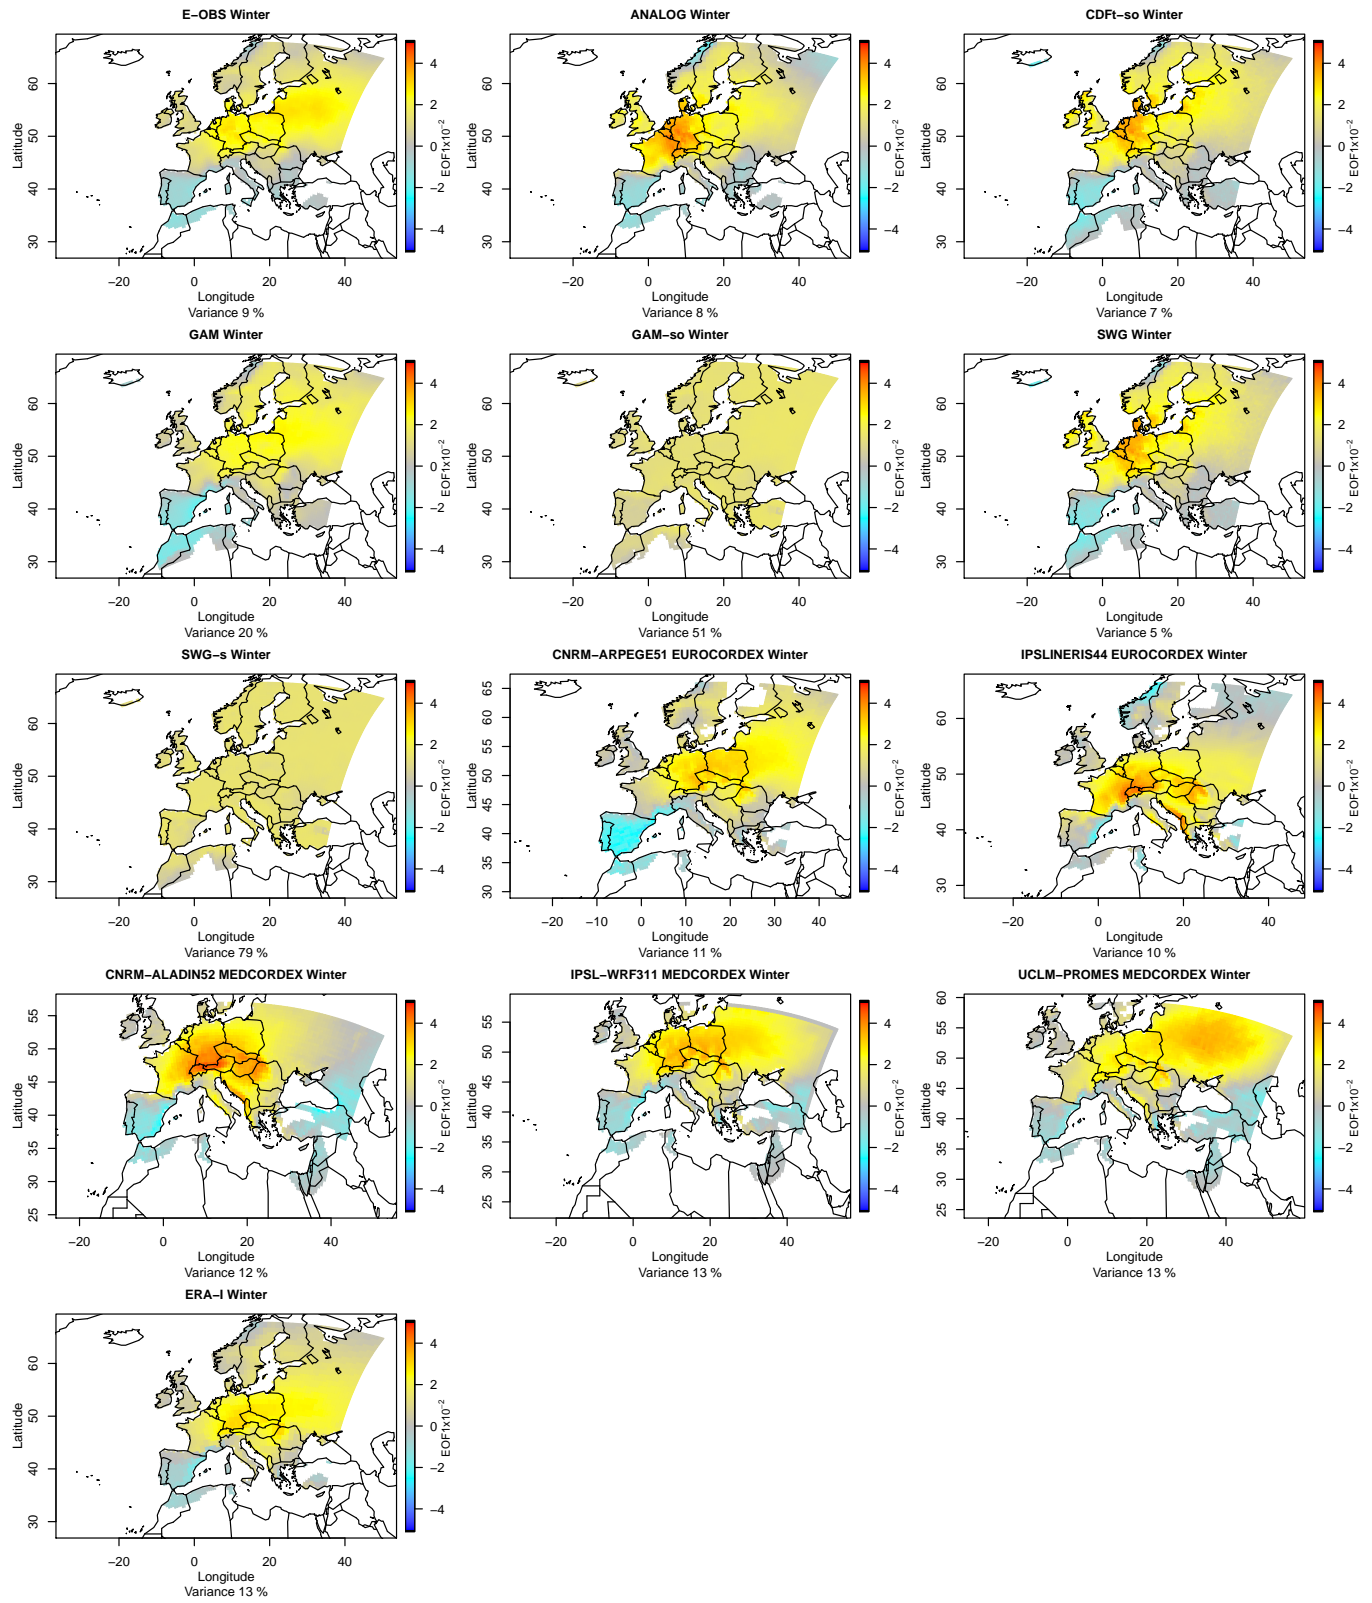


FIGURE A.7 – Idem FIGURE 9 for Winter



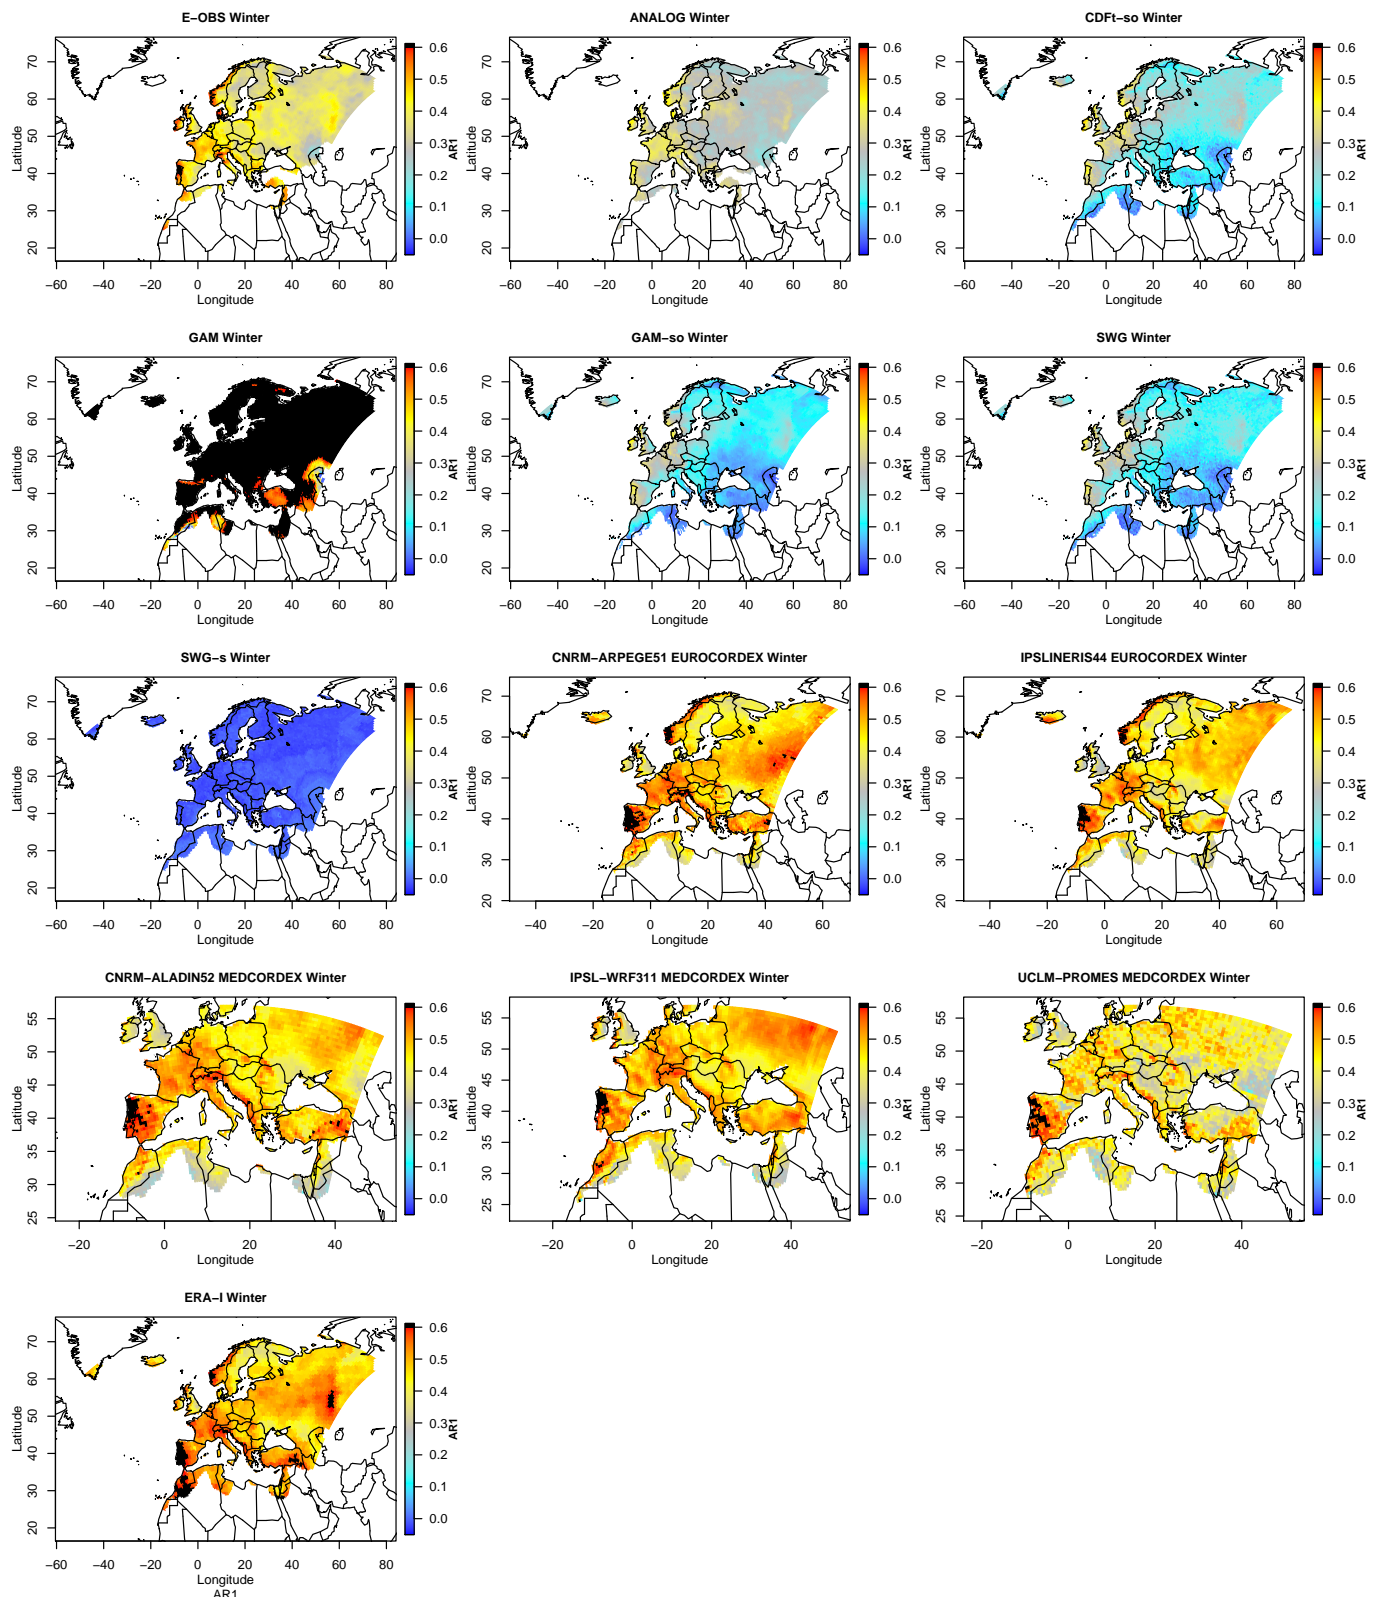


FIGURE A.8 – Idem FIGURE 14 for Winter

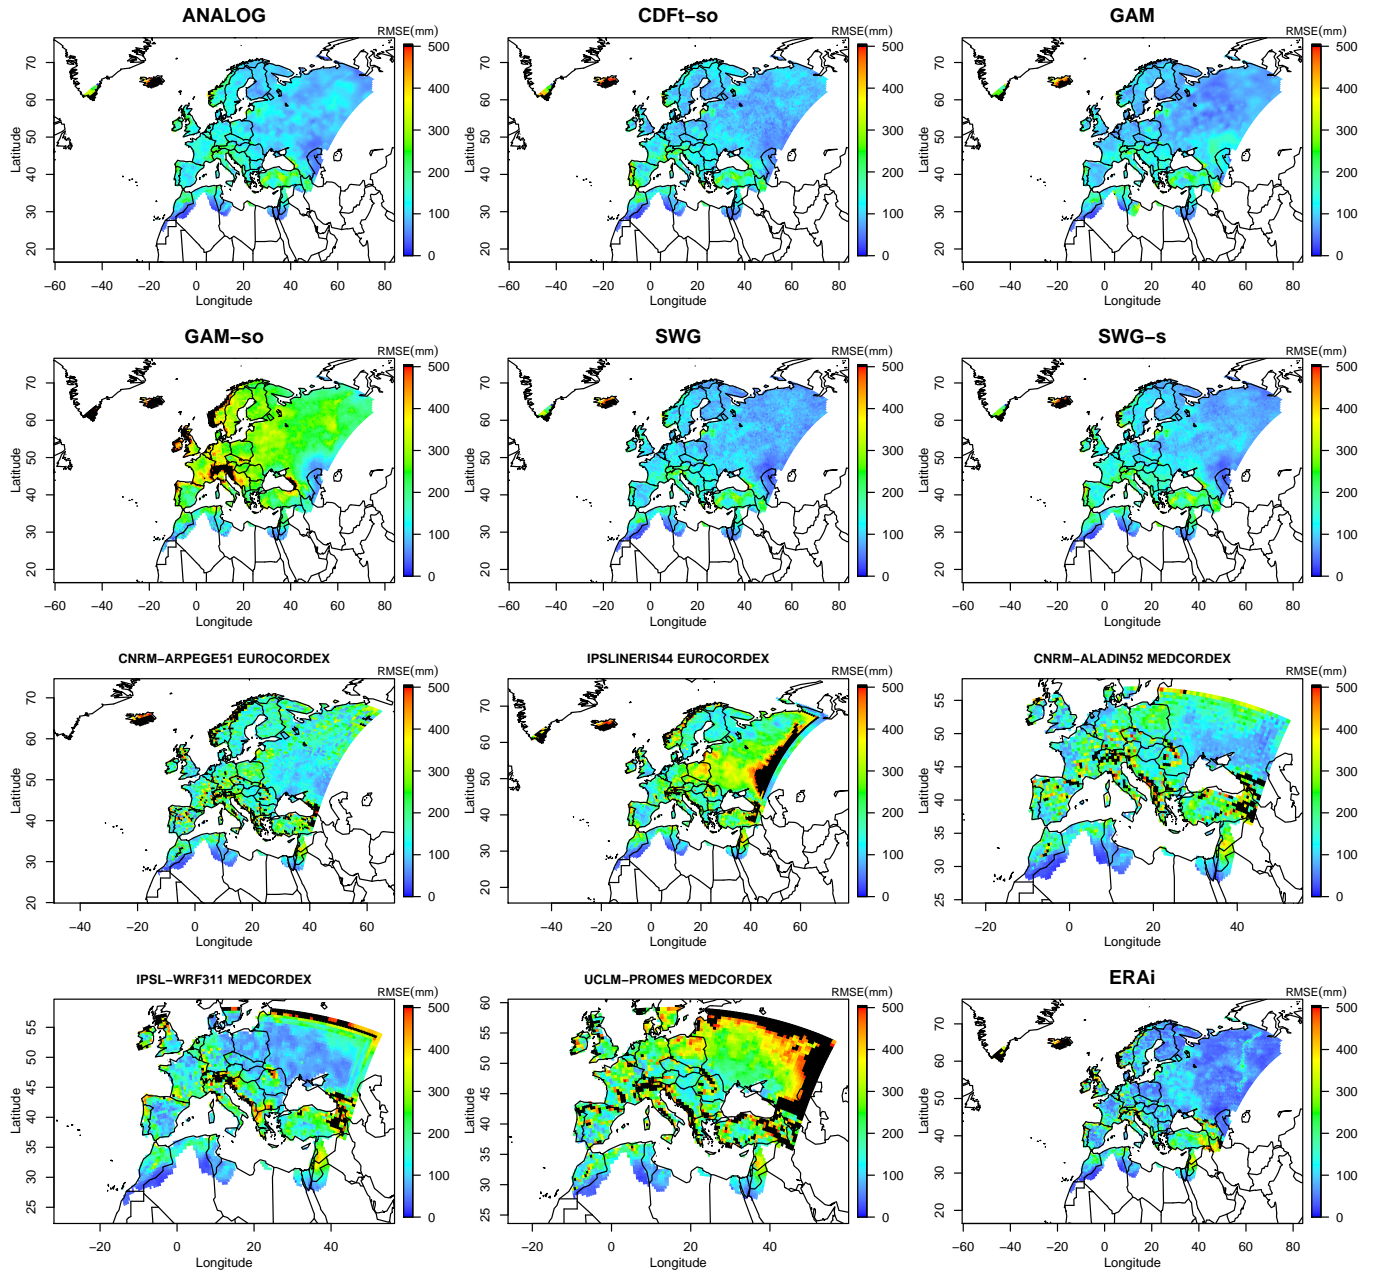


FIGURE A.9 – RMSE. Only values below 500 are represented, above they are saturated in *black*.

Model	ANALOG	CDFt-so	GAM	GAM-so	SWG	SWG-s	EURO-CNRM	EURO-IPSL	MED-CNRM	MED-IPSL	MED-UCLM	ERA-I
Wet days % bias	-0.30(2)	0.11(1)	32.73(9)	0.11(1)	0.11(1)	0.64(3)	1.16(4)	1.78(6)	4.29(7)	-1.26(5)	5.60(8)	1.48
Wet mean persistence	-0.27(6)	-0.61(7)	6.25(9)	-0.61(7)	-0.61(7)	-0.83(8)	0.05(1)	-0.12(2)	0.12(2)	-0.19(5)	0.17(4)	0.04
Dry mean persistence	-5.96(8)	-4.88(6)	61.86(9)	-4.88(6)	-4.88(6)	-5.90(7)	-0.74(2)	0.03(1)	-4.05(5)	-2.07(3)	-3.21(4)	-2.03
Brier Score	0.29(8)	0.16(1)	0.41(9)	0.16(1)	0.16(1)	0.19(3)	0.24(5)	0.26(7)	0.20(4)	0.16(1)	0.24(5)	0.17
<b>Total Rank Occurrence</b>	24	15	36	15	15	21	<b>12</b>	16	18	14	21	-
Mean bias mm	-0.20(3)	1.08(9)	-3.18(11)	-1.69(10)	0.14(2)	0.06(1)	-0.31(6)	0.30(5)	-0.32(7)	0.67(8)	0.28(4)	-1.14
Variance Ratio%	93.19(2)	129.50(6)	4.20(11)	27.61(10)	97.00(1)	82.49(3)	123.36(4)	184.98(7)	127.85(5)	193.20(9)	190.85(8)	78.24
Q99 bias mm	-1.14(4)	3.11(6)	-19.29(11)	-5.65(9)	-0.08(1)	-2.44(5)	0.48(3)	4.76(7)	0.31(2)	5.46(8)	5.81(10)	-4.75
<b>Total Rank Intensity</b>	9	21	33	29	<b>4</b>	9	13	19	14	25	22	-
EOF1	4	4	1	11	4	11	3	8	8	7	1	-
Spatial pattern correlation	0.23(9)	0.27(8)	0.32(6)	0.28(7)	0.19(10)	0.11(11)	0.36(4)	0.36(4)	0.49(2)	0.62(1)	0.41(3)	0.53
<b>Total Rank Spatial</b>	13	12	7	18	14	22	7	12	10	8	<b>4</b>	-
Cor. Annual Amount	0.26(9)	0.46(4)	0.34(7)	0.27(8)	0.20(10)	-0.10(11)	0.43(5)	0.37(6)	0.58(2)	0.63(1)	0.50(3)	0.69
Cor. Seas. Cycle	0.80(3)	0.81(2)	0.87(1)	0.75(5)	0.80(3)	0.58(9)	0.58(9)	0.61(7)	0.61(7)	0.49(11)	0.68(6)	0.85
AR1 (E-OBS :0.42)	0.30(6)	0.17(8)	0.65(7)	0.13(9)	0.13(9)	-0.01(11)	0.48(5)	0.44(2)	0.46(4)	0.44(2)	0.42(1)	0.52
<b>Total Rank Temporal</b>	18	14	15	22	22	31	19	15	<b>13</b>	14	10	-

Tableau A.1 – Score and rank table for winter season computed over the MEDCORDEX domain. The value corresponds to the mean over the domain and their rank is indicated into bracket.

Model	ANALOG	CDFt-so	GAM	GAM-so	SWG	SWG-s	EURO-CNRM	EURO-IPSL	ERA-I
Wet days % bias	-0.33(3)	0.06(2)	31.09(6)	0.06(2)	0.06(2)	0.04(1)	1.12(4)	2.53(5)	1.16
Wet mean persistence	-0.24(3)	-0.59(4)	6.61(6)	-0.59(4)	-0.59(4)	-0.85(5)	0.05(2)	-0.04(1)	0.04
Dry mean persistence	-3.51(4)	-2.88(3)	45.04(6)	-2.88(3)	-2.88(3)	-3.75(5)	-0.54(1)	0.54(1)	-0.76
Brier Score	0.32(5)	0.17(1)	0.40(6)	0.17(1)	0.17(1)	0.20(2)	0.26(3)	0.27(4)	0.17
<b>Total Rank Occurrence</b>	15	10	24	10	10	13	10	11	-
Mean bias mm	-0.18(4)	0.92(6)	-2.69(8)	-1.66(7)	0.11(2)	0.03(1)	-0.14(3)	0.30(5)	-0.96
Variance Ratio%	91.65(2)	125.80(4)	5.10(8)	23.14(7)	95.85(1)	81.64(3)	127.91(5)	181.26(6)	79.27
Q99 bias mm	-1.08(3)	2.62(5)	-16.55(8)	-6.38(7)	-0.08(1)	-2.11(4)	0.62(2)	3.96(6)	-4.01
<b>Total Rank Intensity</b>	9	15	24	21	4	8	10	17	-
EOF1	4	4	1	8	4	8	3	7	-
Spatial pattern correlation	0.24(6)	0.29(4)	0.32(3)	0.28(5)	0.20(7)	0.10(8)	0.37(1)	0.37(1)	0.53
<b>Total Rank Spatial</b>	10	8	4	13	11	16	4	8	-
Cor. Annual Amount	0.27(6)	0.50(1)	0.38(3)	0.32(5)	0.25(7)	-0.05(8)	0.42(2)	0.38(3)	0.72
Cor. Seas. Cycle	0.83(4)	0.85(2)	0.90(1)	0.80(5)	0.84(3)	0.59(8)	0.65(7)	0.69(6)	0.88
AR1 (E-OBS :0.41)	0.30(3)	0.18(4)	0.66(5)	0.14(6)	0.14(6)	-0.01(8)	0.46(2)	0.41(1)	0.51
<b>Total Rank Temporal</b>	13	7	9	16	16	24	11	10	-

Tableau A.2 – Score and rank table for winter season computed over the EUROCORDEX domain. The value corresponds to the mean over the domain and their rank is indicated into bracket.



Model	Wet days % bias	Wet mean persistence bias	Dry mean persistence bias	Mean bias mm	Variance Ratio%	Q99 bias mm
ANALOG	[-8.85,8.83]	[-1.33,0.79]	[-3658.83,1830.50]	[-4.33,10.06]	[0.08,964.50]	[-22.59,25.13]
CDFt-so	—	—	—	[-5.98,12.98]	[0.00,983.77]	[-19.15,49.84]
GAM	[-13.09,71.72]	[-0.69,94.19]	[-3645.14,3643.01]	[-10.48,3.44]	[0.00,438.96]	[-64.67,12.36]
GAM-so	—	—	—	[-8.75,231.29]	[0.00,990.11]	[-53.97,443.16]
LR/SWG	[-9.03,7.76]	[-1.75,0.65]	[-3645.85,697.48]	[-3.80,73.41]	[0.53,941.68]	[-25.57,262.24]
COP/SWG-s	[-9.56,8.32]	[-2.21,0.00]	[-3645.69,1307.79]	[-5.50,6.48]	[0.02,884.71]	[-25.29,14.99]
EURO-CNRM	[-28.33,57.16]	[-1.13,12.70]	[-3576.19,1307.64]	[-7.82,5.54]	[0.01,831.93]	[-39.87,38.44]
EURO-IPSL	[-20.66,31.31]	[-1.26,1.78]	[-3593.43,203.33]	[-7.83,9.68]	[1.05,978.31]	[-27.26,62.12]
MED-CNRM	[-10.96,48.50]	[-0.99,8.30]	[-3642.30,305.00]	[-7.18,5.33]	[5.44,659.12]	[-45.03,28.25]
MED-IPSL	[-26.94,36.15]	[-2.54,5.16]	[-3632.87,1423.83]	[-7.04,8.21]	[1.80,999.84]	[-34.80,44.51]
MED-UCLM	[-28.44,42.05]	[-1.19,7.28]	[-3621.30,3254.33]	[-5.90,9.34]	[5.07,996.59]	[-23.21,101.71]
ERA-I	[-14.89,37.54]	[1.52,2.48]	[-3655.51,813.78]	[-10.27,3.20]	[0.63,989.55]	[-48.97,29.87]

Tableau A.3 – Figure range in summer.

Model	Wet days % bias	Wet mean persistence bias	Dry mean persistence bias	Mean bias mm	Variance Ratio%	Q99 bias mm
ANALOG	[-15.06,12.54]	[-1.69,0.39]	[-3642.79,29.99]	[-2.87,2.85]	[8.25,606.55]	[-29.10,31.81]
CDFt-so	—	—	—	[-2.30,2.85]	[17.49,641.19]	[-20.13,44.85]
GAM	[-14.10,73.77]	[-0.86,43.44]	[-3642.12,3632.24]	[-12.70,-0.74]	[0.00,31.90]	[-79.67,-4.13]
GAM-so	—	—	—	[-9.34,41.31]	[2.53,997.61]	[-68.83,454.56]
LR/SWG	[-14.37,11.60]	[-2.32,0.00]	[-3636.99,18.74]	[-2.28,47.17]	[13.51,982.52]	[-25.27,964.57]
COP/SWG-s	[-14.21,11.70]	[-4.43,-0.12]	[-3636.59,8.62]	[-6.27,4.04]	[14.47,280.05]	[-28.88,20.19]
EURO-CNRM	[-26.86,40.82]	[-3.27,3.93]	[-473.27,211.75]	[-11.60,9.66]	[2.14,958.50]	[-52.30,49.90]
EURO-IPSL	[-22.61,28.42]	[-3.09,2.60]	[-450.40,288.83]	[-9.68,13.62]	[12.02,989.76]	[-35.99,70.11]
MED-CNRM	[-18.33,30.10]	[-3.26,2.07]	[-3637.12,61.64]	[-9.90,7.24]	[4.61,995.09]	[-55.21,35.44]
MED-IPSL	[-29.44,20.74]	[-4.26,1.19]	[-3637.50,497.17]	[-9.52,11.44]	[8.64,993.84]	[-45.27,57.81]
MED-UCLM	[-22.61,34.18]	[-2.22,2.60]	[-3638.85,705.26]	[-9.48,18.84]	[2.97,960.05]	[-35.08,131.14]
ERA-I	[19.48,42.80]	[-3.00,2.75]	[-3641.57,134.26]	[-11.46,5.51]	[4.21,690.02]	[-64.72,32.48]

Tableau A.4 – Figure range in winter.



# Continuité et dérivabilité d'un processus spatial

On énonçant ici quelques propriétés de continuité et de dérivabilité d'un processus aléatoire. Il n'y a pas de relation simple entre la fonction de covariance et la régularité du processus qui en découle. Cependant il est possible de relier la fonction de covariance aux propriétés en moyenne quadratique des champs aléatoires. Plus de détails et d'éléments théoriques sont disponibles dans ADLER [1981] et STEIN [1999].

**Définition B.1** Soit  $\mathbf{s}_1, \mathbf{s}_2, \dots$  une suite de points et  $\mathbf{s}_*$  un point fixé de  $\mathbb{R}^d$  tel que  $|\mathbf{s}_k - \mathbf{s}_*| \rightarrow 0$  lorsque  $k \rightarrow \infty$ .

Alors un processus  $Y(\mathbf{s})$  est continu en moyenne quadratique en  $\mathbf{s}_*$  si  $\mathbb{E}[|Y(\mathbf{s}_k) - Y(\mathbf{s}_*)|^2] \rightarrow 0$  lorsque  $k \rightarrow \infty$ . Si cela est valable pour tout  $\mathbf{s}_* \in A$ , un sous ensemble de  $\mathbb{R}^d$  alors  $Y(\mathbf{s})$  est continue en moyenne quadratique (MQ) sur  $A$ .

Un processus aléatoire est MQ continu en  $\mathbf{s}_*$  si et seulement si sa fonction de covariance  $C(\mathbf{s}, \mathbf{s}')$  est continue en  $\mathbf{s} = \mathbf{s}' = \mathbf{s}_*$ , ce qui revient à vérifier la continuité en  $C(0)$  dans le cas stationnaire.

On peut alors dans le cas stationnaire définir la dérivée suivante :

$$Y'(\mathbf{s}) = \lim_{h \rightarrow 0} \frac{Y(\mathbf{s} + h) - Y(\mathbf{s})}{h}. \quad (\text{B.1})$$

La fonction de covariance de  $Y'(\mathbf{s})$  est  $C''(h)$  STEIN [1999].

**Définition B.2** Un processus aléatoire  $Y(\mathbf{s})$  est MQ dérivable en  $\mathbf{s}$  si et seulement si  $C''(0)$  existe et est finie.

On peut étendre facilement cette définition aux dérivées d'ordres supérieures [STEIN, 1999]. Un processus stationnaire est  $p$  fois MQ dérivable si sa fonction covariance est  $2p$  dérivable et que  $C^{2p}(0)$  existe et est finie.





---

## Matériel supplémentaire chapitre IV

---

---

### Liste des figures

C.1 Cycle saisonnier – Matérn . . . . .	198
---	-----

---

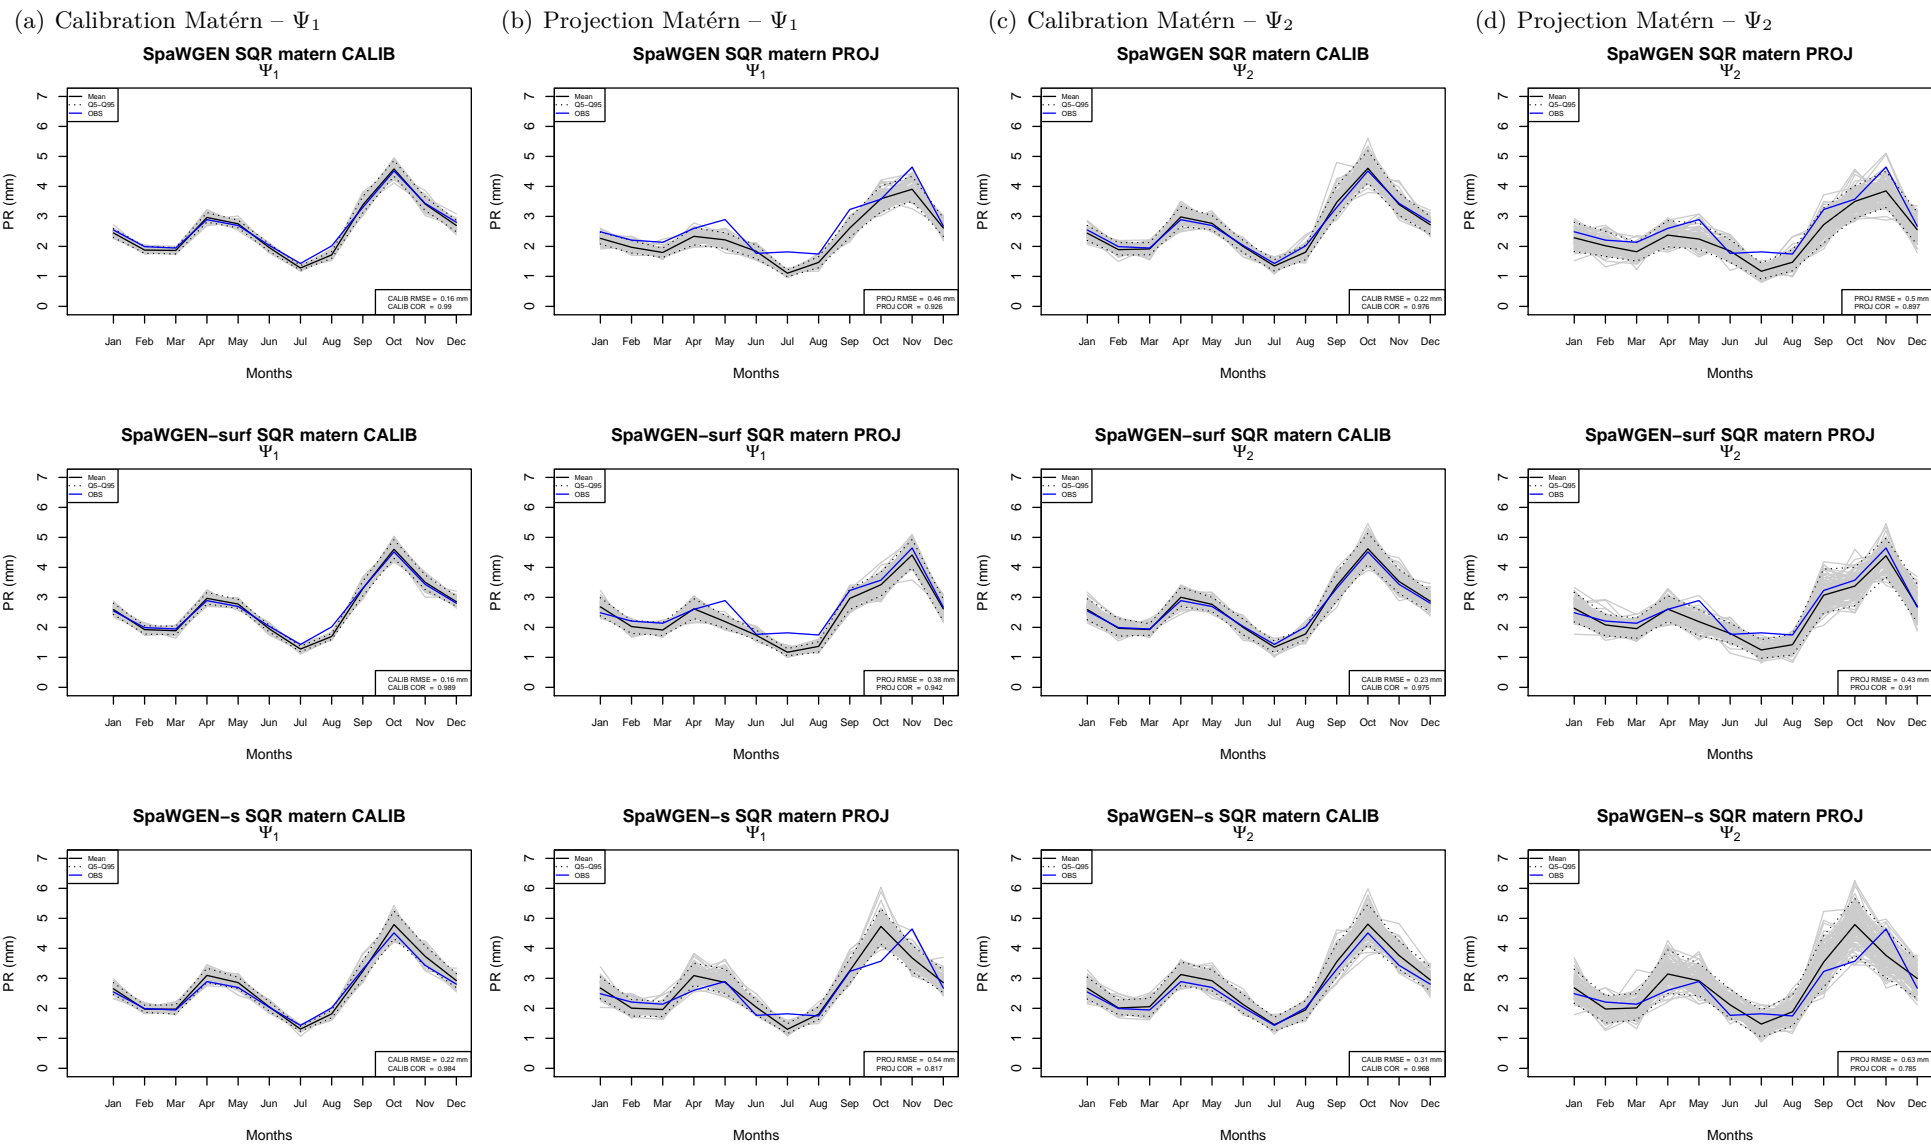


FIGURE C.1 – Idem FIGURE IV.7 pour la fonction de covariance de Matérn



